



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

“POR LA CUAL SE HOMOLOGA EL PROGRAMA DE MAESTRÍA EN CIENCIAS EN INTELIGENCIA ARTIFICIAL DE LA FACULTAD DE INGENIERÍA”

VISTO Y CONSIDERANDO: El orden del día;

La Nota N° 851/2022 de la **Facultad de Ingeniería**, con referencia de la Mesa de Entradas del Rectorado de la UNA número 49.355 de fecha 07 de diciembre de 2022, por la que eleva la Resolución CD N° 1514/2022/012 de fecha 17 de noviembre de 2022 del Consejo Directivo “POR LA CUAL SE APRUEBA EL PROYECTO ACADÉMICO DEL PROGRAMA DE POSTGRADO DE LA MAESTRÍA EN CIENCIAS EN INTELIGENCIA ARTIFICIAL”, para su homologación.

El dictamen de la Comisión Asesora Permanente de Asuntos de Investigación, Postgrado y Extensión Universitaria, de fecha 14 de febrero de 2023, que se transcribe a continuación:

“Dictamen CIPEU N° 41/2022:

La comisión ha analizado el expediente de referencia y teniendo en cuenta el informe técnico contenido en la NOTA DGPRI N° 01/2023, sugiere aprobar con modificaciones “EL PROGRAMA DE MAESTRÍA EN CIENCIAS EN INTELIGENCIA ARTIFICIAL DE LA FACULTAD DE INGENIERÍA”

Salvo mejor parecer del Consejo Superior Universitario.”

La Ley 4995/2013 “De Educación Superior” y el Estatuto de la Universidad Nacional de Asunción;

EL CONSEJO SUPERIOR UNIVERSITARIO, EN USO DE SUS ATRIBUCIONES LEGALES, RESUELVE:

0057-01-2023 **Homologar** el Programa de Maestría en Ciencias en Inteligencia Artificial de la Facultad de Ingeniería, tal como sigue:

4. PROYECTO ACADÉMICO

4.1. Identificación del proyecto académico

DENOMINACIÓN DEL PROGRAMA	Maestría en Ciencias de la Inteligencia Artificial
NIVEL	Maestría
ORIENTACIÓN	Académica
TÍTULO QUE OTORGARÁ	Magister en Ciencias de la Inteligencia Artificial
MODALIDAD	Presencial
SEDE/FILIAL	Sede San Lorenzo
ÁMBITO INSTITUCIONAL	Institucional
DATOS DE LA IES ASOCIADA	No aplica
NÚMERO DE COHORTE	Primera convocatoria
DURACIÓN DEL PROGRAMA	24 meses
PERIODO ACADÉMICO	4 semestres



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(2)

TOTAL DE CARGA HORARIA DEL PROGRAMA	2370 horas
TOTAL DE CARGA HORARIA DE DOCENCIA	2160 horas
TOTAL DE CARGA HORARIA DE INVESTIGACIÓN	180 horas
TOTAL DE CARGA HORARIA DE EXTENSIÓN Y/O RESPONSABILIDAD SOCIAL	30 horas
TOTAL DE CRÉDITOS ACADÉMICOS (SNC CONES)	79
DÍAS Y HORARIO DE ACTIVIDADES ACADÉMICAS	Lunes a Viernes, 8:00 - 16:00 (tentativo)
PLAZAS DISPONIBLES	20
CLASIFICACIÓN DEL ÁREA DEL SABER SEGÚN CONES	Ingeniería y Tecnología
ÁREA PRIORIZADA POR CONACYT QUE IMPACTA	
OBJETIVOS DEL PLAN NACIONAL 2030 QUE IMPACTA	Estrategia 2.2 de Competitividad e Innovación

4.2. Fundamentos del Proyecto Académico

4.2.1. Fundamentación

La Facultad de Ingeniería de la Universidad Nacional de Asunción (FIUNA) se constituye en una referencia en la formación de Ingenieros Paraguayos, con más de 90 años de tradición académica. La FIUNA posee una Dirección de Investigación que está encargada de la organización y coordinación de la investigación en el campo de las ciencias de la Ingeniería relacionadas con las necesidades del desarrollo científico y tecnológico del país. Una de sus líneas de investigación más recientes se centra en el uso de técnicas de Inteligencia Artificial (IA) con aplicaciones a la robótica, agricultura de precisión, sistemas embebidos, bioelectrónica y biología computacional. En este contexto, estas líneas de investigación han sido afianzadas recientemente a través de la concesión de proyectos por parte del Consejo Nacional de Ciencia y Tecnología (CONACYT) que han permitido el fortalecimiento institucional de la FIUNA, por una lado, a través de la dotación de equipos de instrumentación de última generación, y por otro, mediante la creación de una infraestructura de vanguardia que permite abordar el desarrollo de Tesis de Maestrías en el ámbito de la Inteligencia Artificial. En este sentido, el desarrollo del programa de Maestría propuesto, se encuentra respaldado por la experiencia previa de los docentes investigadores de la FIUNA, mediante el establecimiento de líneas concretas investigación y desarrollo en el campo de las IA.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(3)

En el contexto de unas de las metas establecidas en El PLAN NACIONAL DE DESARROLLO PARAGUAY 2030, la presente Maestría en Ciencias en Inteligencia Artificial (MSCIA) contribuiría con el incremento de la innovación en los sectores productivos como factor de competitividad (Estrategia 2.2 de Competitividad e Innovación). Primero, a través del desarrollo de capital humano avanzado en el área emergente de la IA, y, segundo, mediante la transferencia de los conocimientos adquiridos a las esferas económicas e industriales para su adopción y explotación. En el contexto global, el Foro Económico Mundial, en su reciente reporte "Data Science in the New Economy" se ha referido a la ciencia de datos e IA como parte responsable de la cuarta revolución industrial. Los datos son el nuevo petróleo de la economía global, mientras que los científicos e ingenieros de datos e IA, como los talentos que poseen la habilidad para extraer, refinar y desplegar esta nueva fuente de valor dentro de la economía global. Se estima que la adopción y desarrollo de nuevas tecnologías basadas en la Ciencia de Datos e Inteligencia Artificial creará un mercado de billones de dólares.

La presente Maestría en Ciencias en Inteligencia Artificial ofrecerá una sólida formación en técnicas de aprendizaje de máquina, análisis de datos, y manejo de proyectos de IA de gran escala. El MSCIA propone una formación multidisciplinaria en la intersección de la metodología estadística, la ciencia computacional y las técnicas de IA en diversas áreas de aplicación. El programa que se propone ofrece una sólida preparación en modelado estadístico, aprendizaje de máquina, optimización, gestión y análisis de conjuntos de datos masivos y adquisición de datos. El curso permitirá a los graduados adquirir las habilidades matemáticas para comprender e implementar métodos modernos de aprendizaje automático estadístico, dominar los fundamentos de la IA, familiarizarse con una variedad de técnicas actuales de aprendizaje automático e IA y desarrollar una visión de los problemas involucrados en su aplicación. Esto permitirá a los graduados desarrollar la capacidad de evaluar la efectividad de implementaciones particulares, manejar datos y escenarios del mundo real, y para aplicar y ajustar técnicas de IA en aplicaciones reales. A través de un módulo intensivo sobre programación en Python con un enfoque en aplicaciones de IA y el uso de Python en otros módulos sobre aprendizaje automático, el MSCIA también permitirá a los estudiantes graduarse como programadores expertos de IA.

4.2.2. Objetivo general del programa

La Maestría en Ciencias de la Inteligencia Artificial tiene como objetivo general formar a profesionales del ámbito de la ingeniería capacitados en la extracción, modelado matemático y visualización de datos. Los profesionales serán capaces de formular soluciones de aprendizaje de máquina en torno a problemas que surgen en diversas áreas relevantes para el desarrollo nacional acorde al Plan Nacional de Desarrollo 2030.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(4)

4.2.3. Objetivos específicos del programa

- Nivelar a los estudiantes en técnicas matemáticas avanzadas necesarias como base para el estudio de las técnicas de IA.
- Capacitar a los estudiantes en el uso del lenguaje de programación Python y su aplicación en aprendizaje de máquina
- Enseñar a los estudiantes la formulación de los principales problemas de aprendizaje máquina (aprendizaje supervisado vs no-supervisado).
- Familiarizar a los estudiantes con los recursos en la nube disponibles para el procesamiento de datos a gran escala
- Capacitar a los estudiantes con las técnicas de vanguardia de la inteligencia artificial tales como el aprendizaje de máquina, las redes neuronales, el aprendizaje profundo, sistemas de recomendación entre otros
- Capacitar a los estudiantes sobre el ciclo de elaboración de proyectos donde se utilicen inteligencia artificial
- Aplicar las técnicas de inteligencia artificial adquiridas en áreas relevantes del desarrollo nacional como la agricultura, ganadería, medio ambiente, sistema eléctrico nacional, etc.

4.2.4. Misión del programa

Formar a profesionales altamente competentes del ámbito de la Inteligencia Artificial a nivel postgrado mediante una Maestría que les capacite en el diseño y la ejecución de proyectos que impliquen recolección de datos y el modelado matemático predictivo utilizando técnicas avanzadas de aprendizaje de máquina.

4.2.5. Visión del programa

Ser un programa de Maestría en Ciencias reconocida nacional e internacionalmente por formar recursos humanos especializados en el desarrollo y aplicación de modelos basados en inteligencia artificial a problemas tanto de interés académico, gubernamental o de la industria.

4.2.6. Perfil de ingreso

Podrán cursar esta Maestría ingenieros/as de las ramas de electrónica, informática, electricidad, electromecánica, mecánica, industrial, civil, y egresados de carreras afines con grado de licenciatura, de una universidad paraguaya reconocida por el CONES o de una universidad extranjera con la convalidación correspondiente a las reglamentaciones académicas.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(5)

4.2.7. Requisitos de admisión

- Formulario de inscripción debidamente completado;
- Presentar Currículo Vitae actualizado en formato FIUNA o CONACYT (CVpy);
- Presentar foto tipo carnet (2) dos;
- Presentar una copia del Diploma de Grado y del Certificado de Estudios, debidamente autenticados por el Rectorado de la UNA.
- Presentar una copia autenticada de la cédula de identidad civil vigente, o en el caso de extranjeros radicación y copia autenticada de pasaporte.
- Presentar documento de compromiso personal o institucional, asumiendo la responsabilidad del pago de aranceles correspondientes;

4.2.8. Perfil de egreso

- Disponer de los fundamentos necesarios de la inteligencia artificial, como la estadística avanzada, álgebra lineal, cálculo matricial y la optimización de funciones.
- Disponer de conocimientos necesarios para formular problemas en términos de aprendizaje de máquina: problemas supervisados versus no-supervisados.
- Conocer las técnicas de aprendizaje de máquina aplicables en problemas que impliquen regresión, clasificación o agrupamiento (clustering).
- Conocer arquitecturas de aprendizaje profundo dependiendo del tipo de dato a utilizar (tablas, imágenes, series temporales).
- Conocer cómo procesar grandes cantidades de datos, procesamiento con GPUs (Unidades de Procesamiento Gráfico, en inglés) vs CPUs (Unidades de Procesamiento Central, en inglés), y su almacenamiento.
- Conocer el ciclo completo de proyectos de inteligencia artificial, desde su formulación hasta su ejecución y el proceso iterativo que implica agregar nuevos datos al sistema.
- Estar capacitado para trabajar en equipos multidisciplinarios que requieran aplicar técnicas de IA a diversos problemas.

4.2.9. Requisitos de egreso

Para la graduación los estudiantes tienen que haber cumplido con los siguientes requisitos:

- Haber abonado la totalidad de las cuotas de los 12 módulos y de la tutoría de tesis



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(6)

- Haber alcanzado como mínimo un promedio del 60% en las evaluaciones de los módulos
- Haber entregado el trabajo de tesis de maestría en plazo y en forma.
- Haber defendido el trabajo de tesis ante un jurado con un porcentaje mínimo del 60%.
- Haber presentado al menos un artículo científico en un congreso internacional o workshop arbitrado.

4.2.10. Requisitos de para la obtención del título

Para la obtención del título los estudiantes tienen que haber cumplido con los siguientes requisitos:

- Haber cumplido con todos los requisitos de egreso.
- Haber abonado el monto correspondiente a la titulación.

4.2.11. Plan de estudio

TABLA 1. PLAN DE ESTUDIO DEL PROGRAMA ACADÉMICO

PROGRAMA: Maestría en Ciencias de la Inteligencia Artificial

PLAN DE ESTUDIOS – AÑO:2023

Código (propio de la IES)	Periodo académico (trimestre, semestre, año o módulo)	Áreas (docente, investigación o extensión)	Actividad académica (asignatura, actividad de investigación o de extensión)	Denominación de la actividad académica	Carga horaria (horas reloj)	Créditos académicos	Prerrequisitos (código de la actividad prerrequisito)
MSCIA 01	Semestre 1	Docente	Asignatura	Álgebra Lineal Avanzada	180	6	-
MSCIA 02	Semestre 1	Docente	Asignatura	Probabilidad y Estadística Avanzada	180	6	-
MSCIA 03	Semestre 1	Docente	Asignatura	Programación para Análisis de Datos	180	6	-
MSCIA 04	Semestre 1	Docente	Asignatura	Almacenamiento y Procesamiento de Datos a Gran Escala	180	6	-
Carga horaria sub total					720		
Créditos académicos del periodo						24	



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(7)

Código (propio de la IES)	Periodo académico o (trimestre, semestre, año o módulo)	Áreas (docente, investigación o extensión)	Actividad académica (asignatura, actividad de investigación o de extensión)	Denominación de la actividad académica	Carga horaria (horas reloj)	Créditos académicos	Prerrequisitos (código de la actividad prerequisite)
MSCIA 05	Semestre 2	Docente	Asignatura	Aprendizaje de Máquina	180	6	MSCIA 01, MSCIA 02, MSCIA 03
MSCIA 06	Semestre 2	Docente	Asignatura	Introducción a las Redes Neuronales	180	6	MSCIA 05
MSCIA 07	Semestre 2	Docente	Asignatura	Aprendizaje Profundo	180	6	MSCIA 06
MSCIA 08	Semestre 2	Docente	Asignatura	Metodología y Gestión de Proyectos de Investigación	180	6	MSCIA 04
Carga horaria sub total					720		
Créditos académicos del periodo						24	
MSCIA 09	Semestre 3	Docente	Asignatura	Sistemas de Recomendación	180	6	MSCIA 05
MSCIA 10	Semestre 3	Docente	Asignatura	Series Temporales	180	6	MSCIA 07
MSCIA 11	Semestre 3	Docente	Asignatura	Algoritmos para Aprendizaje No Supervisado	180	6	MSCIA 05
MSCIA 12	Semestre 3	Docente	Asignatura	AI aplicada a Robótica	180	6	MSCIA 07
Carga horaria sub total					720		
Créditos académicos del periodo						24	
MSCIA 13	Semestre 4	Investigación	Investigación	Investigación Orientada para la Maestría	180	6	MSCIA 09 MSCIA 10 MSCIA 11 MSCIA 12
Carga horaria sub total					180		
Créditos académicos del periodo						6	
MSCIA 14		Extensión	Extensión	Extensión Universitaria	30	1	
Carga horaria total					2370	79	



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(8)

RESUMEN:

Duración del programa	24 meses
Carga horaria total	2370
Carga horaria docencia	2160
Carga horaria investigación	180
Carga horaria extensión	30
Carga horaria práctica	-
Créditos académicos (total)	79

TABLA 1.1. DESGLOSE DE HORAS POR SEMESTRE Y MÓDULOS

Semestr e	Nivel de Maestría - Semestres 1 a 4:				Relación HTI 1:3				
	Asignatur a	HTD	HTI	HS	PL	THD	HTAI	THA	Crédito
1	Módulo 1	9	27	36	5	45	135	180	6
	Módulo 2	9	27	36	5	45	135	180	6
	Módulo 3	9	27	36	5	45	135	180	6
	Módulo 4	9	27	36	5	45	135	180	6
	Total Semanas Semestre 1				20	180	540	720	24
2	Módulo 5	9	27	36	5	45	135	180	6
	Módulo 6	9	27	36	5	45	135	180	6
	Módulo 7	9	27	36	5	45	135	180	6
	Módulo 8	9	27	36	5	45	135	180	6
	Total Semanas Semestre 2				20	180	540	720	24
3	Módulo 9	9	27	36	5	45	135	180	6
	Módulo 10	9	27	36	5	45	135	180	6
	Módulo 11	9	27	36	5	45	135	180	6
	Módulo 12	9	27	36	5	45	135	180	6
	Total Semanas Semestre 3				20	180	540	720	24



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(9)


4	Módulo 13		9	9	20			180	6
	Total Semanas Semestre 4				20		180	180	6
5	Módulo 14							30	1
	TOTALES				80	540	1800	2370	79

Donde **HTD** son las horas de trabajo directo o de acompañamiento del docente en aula, equivalente a la carga horaria semanal de la asignatura; Horas de Trabajo Independiente o autónomo del estudiante con acompañamiento del docente (**HTI**); Horas Semanales (**HS**): sumatoria semanal de las horas: H.T.D. y H.T.I; Periodo Lectivo o Académico (**PL**): lapso de duración de un semestre. Total Horas de trabajo Directo en Aulas (**THD**): resulta de la multiplicación de las Horas de Trabajo Directo en Aula (**HTD**) por el Periodo Lectivo (PL). Total Horas de trabajo académico independiente o autónomo del estudiante (**HTAI**): resulta de la multiplicación de las Horas de Trabajo Independiente del estudiante con acompañamiento del docente (HTI) por el periodo lectivo o académico (PL), en modo semestral; y Total Horas Académicas (**THA**):

4.2.12. Organización curricular

La Maestría está organizada en 12 módulos de asignaturas agrupados en 3 semestres, más un semestre de investigación supervisada. El primer semestre cuenta con 4 módulos, los 2 primeros módulos son de nivelación y profundización de conceptos básicos, seguidamente tienen 2 módulos donde se presentan las herramientas programación. En el segundo semestre se tienen 3 módulos generales donde se introducen los métodos más importantes del área y un módulo de gestión de proyectos de investigación. En el tercer semestre se tienen 4 módulos más específicos de aplicación orientadas a las líneas de investigación y al desarrollo de la tesis de maestría. Finalmente, en el cuarto semestre realizan la investigación supervisada y se elabora la tesis de Maestría.

4.2.13. Estructura curricular





Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(10)

4.2.14. Carga horaria

La carga horaria de la maestría consta de un total de 2370 horas académicas y 79 créditos distribuidos en horas de docencia, de investigación y extensión. Las horas de docencia están distribuidas en horas teóricas y prácticas. Las horas de investigación se realizan bajo la supervisión de tutores académicos que guiarán los trabajos y se espera que los estudiantes implementen modelos inteligentes basados en el estado del arte para resolver las problemáticas planteadas por los tutores, lo cual requerirá de al menos 180 horas de dedicación. Las horas de extensión contempla la publicación y divulgación de los resultados preliminares y finales en reuniones de trabajo, así como también en congresos regionales e internacionales, se contempla un mínimo de 30 horas para desarrollo de este tipo de actividades.

4.2.15. Distribución de Horas teóricas y prácticas

Para las horas teóricas y prácticas se asume una relación 1:2. Las horas de teoría son las dedicadas a la presentación de las clases magistrales para desarrollar los temas del contenido de cada módulo. Las horas prácticas se dedican a la demostración de ejemplos, desarrollo e implementación modelos inteligentes a diferentes problemáticas de acuerdo con el contenido del módulo. Adicionalmente se requieren horas de trabajo independiente (HTI) por parte del estudiante de tal forma a asimilar y entender los conceptos fundamentales que sustentan los modelos inteligentes presentados en las clases teóricas, se asumió una relación 1:3.

4.2.16. Distribución del tiempo de docencia

Las horas de docencia son las HTD y engloban las horas de teóricas y prácticas, se contempla 45 horas de docencia por cada módulo que sumados con las HTAI da un total de 180 horas en el módulo, lo que equivale a 6 créditos académicos.

4.2.17. Distribución del tiempo de investigación

La maestría es de carácter académico y se espera que el trabajo supervisado de investigación sea transversal al desarrollo de los módulos. Al final del segundo semestre los estudiantes podrán plantear sus anteproyectos de tesis de maestría durante el desarrollo del módulo metodología y gestión de proyectos de investigación. El último semestre está destinado al desarrollo, publicación de resultados y la elaboración del libro del Trabajo Final de Maestría.

4.2.18. Distribución del tiempo de extensión

Las principales actividades de extensión a ser realizadas por los estudiantes contemplan actividades de divulgación, organización, participación y presentaciones en eventos científicos, simposios, congresos regionales e internacionales arbitrados de relevancia.

4.2.19. Distribución del tiempo de Práctica

En cada módulo de un total de 45 HTD, se contemplan 30 horas de prácticas guiadas por los docentes con ejemplos de aplicación para facilitar la asimilación e implementación de algoritmos que solucionen los problemas planteados en los diferentes contextos y áreas.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(11)

4.2.20. Programas de estudio

TABLA 2. PROGRAMAS POR MATERIAS

I. Identificación			
Módulo	1	Nombre:	Algebra Lineal Avanzada
Semestre	1	Naturaleza	Teórico-Práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	-	Código	MSCIA01
II. Fundamentación	El álgebra lineal es el estudio de los espacios vectoriales y de sus transformaciones. El concepto de espacio vectorial es omnipresente en la ciencia moderna, y la razón es simple de apreciar. En primer lugar, ofrece una aproximación para el estudio de sistemas complejos no lineales, recurrentes en las ciencias e ingeniería mediante el modelamiento matemático de fenómenos y procesos. En segundo lugar, proporciona el cimiento conceptual para disciplinas de elevado nivel práctico como el álgebra de matrices, métodos numéricos, análisis vectorial, optimización entre otros. En particular, se ha convertido en uno de los pilares matemáticos de la ciencia de datos, al proporcionar el lenguaje apropiado para la automatización y el aprendizaje de máquina.		
III. Objetivos	Objetivo General: Proporcionar el cimiento conceptual de algebra lineal avanzada para disciplinas de elevado nivel práctico como el álgebra de matrices, métodos numéricos, análisis vectorial y la optimización. Objetivos Específicos: • Familiarizar al estudiante con los conceptos de espacio vectorial y sus transformaciones. • Familiarizar al estudiante con la geometría de los espacios vectoriales. • Introducir aplicaciones fundamentales de la teoría de espacios vectoriales al álgebra matricial. • Introducir conceptos básicos de análisis vectorial.		
IV. Contenido	1. Espacios vectoriales 2. Transformaciones y matrices 3. Geometría de espacios vectoriales 4. Cálculo vectorial		
V. Estrategia didáctica	Clases teórico, prácticas y trabajo de investigación independiente.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(12)

VII. Actividad Extensión	No aplica
VIII. Bibliografía básica	1. Deisenroth, M. P., Faisal, A. A. and Ong, C. S.: Mathematics for Machine Learning. Cambridge University Press, 2020. 2. Meyer, C. D.: Matrix Analysis and Applied Linear Algebra. SIAM, 2000. 3. Strang, G.: Linear Algebra and Learning from Data. Cambridge Press, 2019. 4. Ruffini, Paolo. 1799. Teoria Generale delle Equazioni, in cui si Dimostra Impossibile la 5. Soluzione Algebraica delle Equazioni Generali di Grado Superiore al Quarto. Stamperia di S. Tommaso d'Aquino. 6. Rumelhart, David E., Hinton, Geoffrey E., and Williams, Ronald J. 1986. Learning Representations by Back-Propagating Errors. Nature, 323(6088), 533–536. 7. Sæmundsson, Steindor, Hofmann, Katja, and Deisenroth, Marc P. 2018. Meta Reinforcement Learning with Latent Variable Gaussian Processes. In: Proceedings of the Conference on Uncertainty in Artificial Intelligence. 8. Saitoh, Saburo. 1988. Theory of Reproducing Kernels and its Applications. Longman Scientific and Technical. 9. Sarkka, Simo. 2013. Bayesian Filtering and Smoothing. Cambridge University Press. 10. Mitchell, Tom. 1997. Machine Learning. McGraw-Hill.
IX. Bibliografía complementaria	1. Scholkopf, Bernhard, and Smola, Alexander J. 2002. " Learning with Kernels – Support 2. Vector Machines, Regularization, Optimization, and Beyond. MIT Press. 3. Scholkopf, Bernhard, Smola, Alexander J., and Müller, Klaus-Robert. 1997. Kernel " 4. Principal Component Analysis. In: Proceedings of the International Conference on Artificial Neural Networks. 5. Scholkopf, Bernhard, Smola, Alexander J., and Müller, Klaus-Robert. 1998. Nonlinear Component Analysis as a Kernel Eigenvalue Problem. Neural Computation, 10(5), 1299–1319. 6. Scholkopf, Bernhard, Herbrich, Ralf, and Smola, Alexander J. 2001. A Generalized Representer Theorem. In: Proceedings of the International Conference on Computational Learning Theory. 7. Schwartz, Laurent. 1964. Sous Espaces Hilbertiens d'Espaces Vectoriels Topologiques et Noyaux Associés. Journal d'Analyse Mathématique, 13, 115–256. 8. Schwarz, Gideon E. 1978. Estimating the Dimension of a Model. Annals of Statistics, 6(2), 461–464. 9. Shahriari, Bobak, Swersky, Kevin, Wang, Ziyu, Adams, Ryan P., and De Freitas, Nando. 2016. Taking the Human out of the Loop: A Review of Bayesian Optimization. Proceedings of the IEEE, 104(1), 148–175. 10. Shalev-Shwartz, Shai, and Ben-David, Shai. 2014. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press. 11. Shawe-Taylor, John, and Cristianini, Nello. 2004. Kernel Methods for Pattern Analysis. Cambridge University Press. 12. Shawe-Taylor, John, and Sun, Shiliang. 2011. A Review of Optimization Methodologies in Support Vector Machines. Neurocomputing, 74(17), 3609–3618. 13. Shental, Ori, Siegel, Paul H., Wolf, Jack K., Bickson, Danny, and Dolev, Danny. 2008. Gaussian Belief Propagation Solver for Systems of Linear Equations. Pages 1863– 1867 of: Proceedings of the International Symposium on Information Theory. 14. Shewchuk, Jonathan R. 1994. An Introduction to the Conjugate Gradient Method without the Agonizing Pain. 15. Shi, Jianbo, and Malik, Jitendra. 2000. Normalized Cuts and Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 22(8), 888–905.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(13)

I. Identificación			
Módulo	2	Nombre:	Probabilidad y Estadística avanzada
Semestre	1	Naturaleza	Teórico-Práctica
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	Ninguno	Código	MSCIA02
II. Fundamentación	Los modelos de aprendizaje de máquina pueden verse como una extensión de los modelos de inferencia estadísticos. Además, que estos modelos de aprendizaje automático se fundamentan en gran medida en la teoría de la probabilidad.		
III. Objetivos	Objetivo General: Proporcionar conceptos de probabilidad y estadística necesarios para entender y proponer nuevos modelos de aprendizaje de máquina. Objetivos Específicos: • Presentar a los alumnos las principales aplicaciones de la probabilidad y estadística en el aprendizaje de máquina. • Introducir a los alumnos en los fundamentos probabilísticos del aprendizaje supervisado.		
IV. Contenido	1. Estadística, estimación de parámetros y pruebas de hipótesis usando Python. 2. Visualización de Distribuciones (boxtplot, violinplot, etc) 3. Probabilidad y distribuciones usando Python. 4. Estimaciones de parámetros frecuentista versus bayesiana. 5. Introducción a la teoría del aprendizaje estadístico: Riesgo empírico, cotas de error y medidas de capacidad.		
V. Estrategia didáctica	Clases teórico/prácticas y trabajo de investigación independiente.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		
VII. Actividad Extensión	No aplica		
VIII. Bibliografía básica	1. Downey, Allen B. "Think Stats: Probability and Statistics for Programmers; 2e." (2014). 2. Gareth, James, et al. An introduction to statistical learning: with applications in R. Springer, 2013. 3. Bousquet, Olivier, Stéphane Boucheron, and Gábor Lugosi. "Introduction to statistical learning theory." Summer school on machine learning. Springer, Berlin, Heidelberg, 2003. 4. Vapnik, V.: Statistical Learning Theory. John Wiley, New York (1998)		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(14)

VIII Bibliografía básica	5. Anthony, M., Bartlett, P.L.: Neural Network Learning: Theoretical Foundations. Cambridge University Press, Cambridge (1999) 6. Breiman, L., Friedman, J., Olshen, R., Stone, C.: Classification and Regression Trees. Wadsworth International, Belmont, CA (1984) 7. Devroye, L., Györfi, L., Lugosi, G.: A Probabilistic Theory of Pattern Recognition. Springer-Verlag, New York (1996) 8. Duda, R., Hart, P.: Pattern Classification and Scene Analysis. John Wiley, New York (1973) 9. Fukunaga, K.: Introduction to Statistical Pattern Recognition. Academic Press, New York (1972) 10. Kearns, M., Vazirani, U.: An Introduction to Computational Learning Theory. MIT Press, Cambridge, Massachusetts (1994)
IX Bibliografía complementaria	1. Kulkarni, S., Lugosi, G., Venkatesh, S.: Learning pattern classification—a survey. IEEE Transactions on Information Theory 44 (1998) 2178–2206 Information Theory: 1948–1998. Commemorative special issue. 2. Lugosi, G.: Pattern classification and learning theory. In Györfi, L., ed.: Principles of Nonparametric Learning, Springer, Viena (2002) 5–62 3. McLachlan, G.: Discriminant Analysis and Statistical Pattern Recognition. John Wiley, New York. 1992. 4. von Luxburg, U., Bousquet, O., Scholkopf, B.: A compression approach to support vector model selection. The Journal of Machine Learning Research (2004) 293–323 5. McDiarmid, C.: On the method of bounded differences. In: Surveys in Combinatorics 1989, Cambridge University Press, Cambridge (1989) 148–188 6. Vapnik, V., Chervonenkis, A.: On the uniform convergence of relative frequencies of events to their probabilities. Theory of Probability and its Applications 16 (1971) 264–280 7. Hoeffding, W.: Probability inequalities for sums of bounded random variables. Journal of the American Statistical Association 58 (1963) 13–30 8. Ledoux, M., Talagrand, M.: Probability in Banach Space. Springer-Verlag, New York (1991) 9. Sauer, N.: On the density of families of sets. Journal of Combinatorial Theory Series A 13 (1972) 145–147 10. Shelah, S.: A combinatorial problem: Stability and order for models and theories in infinity languages. Pacific Journal of Mathematics 41 (1972) 247–261 11. Alesker, S.: A remark on the Szarek-Talagrand theorem. Combinatorics, Probability, and Computing 6 (1997) 139–144 12. Alon, N., Ben-David, S., Cesa-Bianchi, N., Haussler, D.: Scale-sensitive dimensions, uniform convergence, and learnability. Journal of the ACM 44 (1997) 615–631 13. Cesa-Bianchi, N., Haussler, D.: A graph-theoretic generalization of the SauerShelah lemma. Discrete Applied Mathematics 86 (1998) 27–35 1. Frankl, P.: On the trace of finite sets. Journal of Combinatorial Theory, Series (1983) 41–45 2. Haussler, D.: Sphere packing numbers for subsets of the boolean n-cube with bounded Vapnik-Chervonenkis dimension. Journal of Combinatorial Theory, Series A 69 (1995) 217–232



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(15)

I. Identificación			
Módulo	3	Nombre:	Programación para Análisis de datos
Semestre	1	Naturaleza	Teórico-Computacional
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	Ninguno	Código	MSCIA03
II. Fundamentación	Debido a la constante generación y disponibilidad de una gran cantidad de datos, el análisis de estos se ha vuelto imprescindible para obtener información clave para la toma de decisiones en organizaciones. Por este motivo, resulta indispensable el conocimiento y aplicación de algoritmos basados en la matemática (especialmente en la estadística). Debido a su facilidad de aprendizaje e implementación, y a la gran cantidad de librerías existentes, Python se ha vuelto un lenguaje de programación popular para proyectos de análisis de datos.		
III. Objetivos	Objetivo General: Introducir a los estudiantes a los conceptos claves del lenguaje de Programación Python y su aplicación en aspectos fundamentales del análisis de datos Objetivos Específicos: • Introducir las funcionalidades nativas del lenguaje Python. • Presentar las bibliotecas que permitan manipular datos matriciales. • Conocer las principales bibliotecas de visualización de datos.		
IV. Contenido	1. Principios básicos del lenguaje de programación Python. 2. Ambiente de programación Jupyter. 3. Introducción al análisis de datos. 4. Utilización de <i>numpy</i>. 5. Manejo de datos con <i>pandas</i>. 6. Visualización de datos con Python (<i>matplotlib</i>, <i>seaborn</i>, entre otros). 7. Fundamentos del aprendizaje de máquina e introducción a <i>scikit-learn</i>.		
V. Estrategia didáctica	Clases teórico/prácticas y trabajo de investigación independiente.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		
VII. Actividad Extensión	No aplica		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..../..(16)

VIII. Bibliografía básica	1. Varó, A. M., Sevilla, P. G., & Luengo, I. G. (2014). Introducción a la programación con Python 3. Universitat Jaume I. Servei de Comunicació i Publicacions. 2. McKinney, W. (2017). Python for data analysis: Data wrangling with Pandas, NumPy, and IPython (2nd Edition). O'Reilly Media, Inc. 3. VanderPlas, J. (2016). Python data science handbook: Essential tools for working with data. O'Reilly Media, Inc. 4. Cyrille Rossant. IPython Interactive Computing and Visualization Cookbook - Second Edition. Packt. 2018. 5. Eli Bressert. SciPy and NumPy: Optimizing & Boosting your Python Programming. O'Reilly Media, 2012. 6. Rituraj Dixit. Data Analysis with Python: Introducing NumPy, Pandas, Matplotlib, and Essential Elements of Python Programming. BPB Publications. 2023. 7. AI Publishing. Python NumPy for Beginners: NumPy Specialization for Data Science. AI Publishing. 2022. 8. Robert Johansson. Numerical Python: Scientific Computing and Data Science Applications with Numpy, SciPy and Matplotlib. Apress. 2019 9. Rossant, C. IPython Interactive Computing and Visualization Cookbook. Mumbai: Packt. 2014. 10. Devert, A. matplotlib Plotting Cookbook. Mumbai: Packt. 2014.
IX. Bibliografía complementaria	1. Milovanović, I. (2013). Python Data Visualization Cookbook. Mumbai: Packt. 2. Tosi, S. (2009). Matplotlib for Python Developers. Mumbai: Packt. 3. Yau, N. (2011). Visualize this. Indianapolis: Wiley. 4. Idris, I. Learning NumPy Array. Mumbai: Packt, 2014. 5. Idris, I. Numpy Beginner's Guide. 3rd. Mumbai: Packt, 2015. 6. Idris, I. NumPy Cookbook. Mumbai: Packt, 2012. 7. Rossant, C. Learning IPython for Interactive Computing and Data Visualization. Mumbai: Packt. 2013. 8. Rance D. Necaise. Data Structures and Algorithms Using Python. Wiley. 2010. 9. Alfred V. Aho, John E. Hopcroft, and Jeffrey D. Ullman. Data Structures and Algorithms. Addison-Wesley, Reading, MA, 1983. 10. John L. Bentley. Programming pearls: How to sort. Communications of the ACM, 27(3):287–291, March 1984. 11. John L. Bentley. Programming pearls: The back of the envelope. Communications of the ACM, 27(3):180–184, March 1984. 12. John L. Bentley. Programming pearls: Thanks, heaps. Communications of the ACM, 28(3):245–250, March 1985. 13. John L. Bentley. Programming Pearls. Addison-Wesley, Reading, MA, 1986. 14. John L. Bentley. Programming pearls: The envelope is back. Communications of the ACM, 29(3):176–182, March 1986 15. Timothy Budd. Classic Data Structures. Addison-Wesley, Reading, MA, 2001.

I. Identificación			
Módulo	4	Nombre:	Almacenamiento y procesamiento de datos a gran escala
Semestre	1	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(17)

Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	Ninguno	Código	MSCIA04
II. Fundamentación	El avance de la tecnología ha permitido que la adquisición de datos masivos y su almacenamiento sea una realidad, y esto se volvió transversal en todos los aspectos de la vida (economía, ciencias, salud, medio ambiente, etc.). Sin embargo, obtener conocimiento e información relevante de una extensa cantidad de datos se vuelve muy difícil con las técnicas de procesamiento convencionales, es por eso que aparecen nuevas técnicas, conceptos y métodos para la extracción automática de conocimiento a partir de grandes cantidades de datos almacenados, todos ellos enmarcados en el concepto de Data Mining o Big Data, el cual es el objeto de estudio de este curso, y que soluciona problemas reales en el campo de la investigación científica y la vida misma.		
III. Objetivos	Objetivo General: Entrenar a los estudiantes para que sean capaces de extraer conocimiento oculto relevante a partir de una gran cantidad de datos aplicando técnicas computacionales avanzadas de procesamiento de información, para resolver problemas en el campo de las ciencias, la investigación y la ingeniería de datos. Objetivos Específicos: • Aprender acerca de conceptos relacionados a la Minería de Datos, aplicación de técnicas computacionales avanzadas apropiadas para la adquisición de conocimiento a partir de una extensa base de datos, a gestión, manipulación, almacenamiento y procesamiento de una gran cantidad de datos de calidad. • Aplicar las habilidades adquiridas en el desarrollo de un trabajo práctico basado en un problema real de investigación científica.		
IV. Contenido	1. Introducción a la Minería de Datos. 2. Teoría de Datos. Tipos. Atributos. Calidad. Preprocesamiento. 3. Exploración de Datos. Visualización. Procesamiento Analítico en Línea (OLAP). 4. Análisis de Clasificación. Conceptos y Técnicas. 5. Análisis de Asociación. Conceptos y Técnicas. 6. Clusterización. Conceptos y Técnicas.		
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		
VII. Actividad Extensión	No Aplica.		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..../..(18)

VIII. Bibliografía básica	1. Pang-Ning Tan, Michael Steinbach, Vipin Kumar. <i>Introduction to Data Mining</i>. Pearson Addison Wesley, 2006. 2. Jiawei Han, Micheline Kamber, Jian Pei. <i>Data Mining: Concepts and Techniques. Third Edition</i>. Morgan Kaufmann, Elsevier. 2012. 3. Charu C. Aggarwal. <i>Data Mining: The Textbook</i>. Springer. 2015. 4. Ian H. Witten, Eibe Frank, Mark A. Hall. <i>Data Mining: Practical Machine Learning Tools and Techniques. Third Edition</i>. Morgan Kaufmann, Elsevier. 2011. 5. David L. Olson, Dursun Delen. <i>Advanced Data Mining Techniques</i>. Springer 2008. 6. J. Hartigan. <i>Clustering Algorithms</i>. Wiley, New York, 1975 7. Stephan Kudyba, Big Data, Mining , and Analytics: Components of Strategic Decision Making. CRC Press. 2014. 8. Eagle, Nathan; Greene, Kate. <i>Reality mining : using big data to engineer a better world</i>. The MIT Press. 2014. 9. Jared Dean. <i>Big Data, Data Mining, and Machine Learning: Value Creation for Business Leaders and Practitioners</i>. Wiley. 2014. 10. Fausto Pedro Garcia Marquez. <i>Handbook of Research on Big Data Clustering and Machine Learning</i>. IGI Global. 2019.
IX Bibliografía complementaria	1. Gareth James & Daniela Witten. <i>An Introduction to Statistical Learning: with Applications in R</i>. Springer. 2013 2. Foster Provost & Tom Fawcet. <i>Data Science for Business: What you need to know about data mining and data-analytic thinking</i>. O'Reilly Media, Inc. 2013 3. Berkhin, P. <i>Survey of Clustering Data Mining Techniques</i>. Accrue Software. 2002 4. Berman, J. J. Introduction. In <i>Principles of Big Data</i>. Morgan Kaufmann. 2013. 5. Hartigan, J.A. (1975). <i>Clustering algorithms</i>. New York: Wiley. 6. Kass, G.V. (1980). An exploratory technique for investigating large quantities of categorical data. <i>Applied Statistics</i>, 29, 119–127. (Standard reference for the CHAID algorithm Kass described in his 1975 PhD thesis.) 7. McQueen, J. (1967). Some methods for classification and analysis of ultivariate observations. In <i>Proceedings of 5th Berkeley Symposium on Mathematical Statistics Probability</i>, vol. 1, pp. 281–297. 8. Neville, P. (1999). Growing trees for stratified modeling. <i>Computing Science and Statistics</i>, 30. (Extends the ideas of Sonquist et al. and Alexander and Grimshaw for more independent variables and more types of models.) 9. Rawlings, J.O. (1988). <i>Applied regression analysis: A research tool</i>. Belmont, CA: Wadsworth. 10. SAS Enterprise Miner 12.1. (2012). On-line reference help. Cary, NC: SAS Institute. 11. Schapire, R. E., and Freund, Y. (2012). <i>Boosting: Foundations and Algorithms</i>. Cambridge, MA: MIT Press. 12. Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. <i>Journal of the Royal</i> 13. <i>Statistical Society B (Methodological)</i>, 267–288. 14. Vapnik, V. <i>The nature of statistical learning theory</i>. New York: Springer-Verlag, 1995. 15. Bing-Chao Huang and Michael A. Langston. Practical in-place merging. <i>Communications of the ACM</i>, 31(3):348–352, 1988.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(19)

I. Identificación			
Módulo	5	Nombre:	Aprendizaje de Máquina
Semestre	2	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA01 MSCIA02 MSCIA03	Código	MSCIA05
II. Fundamentación	La Inteligencia Artificial (IA) ha surgido como una tendencia tecnológica global líder para el futuro, la cual ha ido evolucionando no solo en el sector de la tecnología, sino también por ejemplo en sectores agrícolas, automotriz, bancario, médico, etc. Mediante una combinación de técnicas de entrenamiento avanzadas y elementos no lineales y estocásticos, ahora es posible desarrollar algoritmos que puedan manejar datos tabulares, imágenes, texto y audio como entrada y salida.		
III. Objetivos	Objetivo General: Desarrollar la capacidad de crear e implementar algoritmos basados en aprendizaje de máquina para resolver problemas de las ciencias y la ingeniería de datos, analizando los conceptos teóricos para la implementación de algoritmos y realizando de un proyecto integrador. Objetivos Específicos: • Conocer los principales métodos para implementar el aprendizaje supervisado y no supervisado. • Implementar Algoritmos de Optimización para ajustar los parámetros e hiper-parámetros de los modelos. • Identificar las principales métricas de desempeño aplicados los diversos problemas donde se aplica el aprendizaje de máquina.		
IV. Contenido	1. Introducción a la Inteligencia Artificial 2. Visión General de un Sistema Inteligente 3. Optimización para modelos ML 4. Regresiones Lineal 5. Regresión Logística 6. Métricas de Desempeño y regularización		
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		
VII. Actividad Extensión	No Aplica		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(20)

VIII. Bibliografía	1. James, Gareth, et al. <i>An introduction to statistical learning</i>. Vol. 112. New York: springer, 2013. 2. Géron, a. (2019). <i>Hands-on machine learning with scikit-learn, keras, and tensorflow: concepts, tools, and techniques to build intelligent systems</i>. O'reilly media. 3. François Chollet - <i>Deep Learning with Python</i>-Manning (2018). 4. Andrieu, C., N. de Freitas, A. Doucet, and M. I. Jor dan (2003). An introduction to MCMC for machine learning. <i>Machine Learning</i> 50, 5–43. 5. Anthony, M. and N. Biggs (1992). <i>An Introduction to Computational Learning Theory</i>. Cambridge University Press. 6. Bather, J. (2000). <i>Decision Theory: An Introduction to Dynamic Programming and Sequential Decisions</i>. Wiley. 7. Baudat, G. and F. Anouar (2000). Generalized discriminant analysis using a kernel approach. <i>Neural Computation</i> 12(10), 2385–2404. 8. Fletcher, R. (1987). <i>Practical Methods of Optimization</i> (Second ed.). Wiley. 9. Forsyth, D. A. and J. Ponce (2003). <i>Computer Vision: A Modern Approach</i>. Prentice Hall. 10. Freund, Y. and R. E. Schapire (1996). Experiments with a new boosting algorithm. In L. Saitta (Ed.), <i>Thirteenth International Conference on Machine Learning</i>, pp. 148–156. Morgan Kaufmann.
IX. Bibliografía complementaria	1. Jolliffe, I. T. (2002). <i>Principal Component Analysis</i> (Second ed.). Springer. 2. Jordan, M. I. (1999). <i>Learning in Graphical Models</i>. MIT Press. 3. Robbins, H. and S. Monro (1951). A stochastic approximation method. <i>Annals of Mathematical Statistics</i> 22, 400–407. 4. Robert, C. P. and G. Casella (1999). <i>Monte Carlo Statistical Methods</i>. Springer. 5. Shawe-Taylor, J. and N. Cristianini (2004). <i>Kernel Methods for Pattern Analysis</i>. Cambridge University Press. 6. Vapnik, V. N. (1982). <i>Estimation of dependences based on empirical data</i>. Springer. 7. Vapnik, V. N. (1995). <i>The nature of statistical learning theory</i>. Springer. 8. Vapnik, V. N. (1998). <i>Statistical learning theory</i>. Wiley. 9. Wiegerinck, W. and T. Heskes (2003). Fractional belief propagation. In S. Becker, S. Thrun, and K. Obermayer (Eds.), <i>Advances in Neural Information Processing Systems</i>, Volume 15, pp. 455–462. MIT Press. 10. Williams, C. K. I. (1998). Computation with infinite neural networks. <i>Neural Computation</i> 10(5), 1203–1216. 11. Poggio, T. and F. Girosi (1990). Networks for approximation and learning. <i>Proceedings of the IEEE</i> 78(9), 1481–1497. 12. Powell, M. J. D. (1987). Radial basis functions for multivariable interpolation: a review. In J. C. Mason and M. G. Cox (Eds.), <i>Algorithms for Approximation</i>, pp. 143–167. Oxford University Press. 13. Rasmussen, C. E. and C. K. I. Williams (2006). <i>Gaussian Processes for Machine Learning</i>. MIT Press. 14. Rauch, H. E., F. Tung, and C. T. Striebel (1965). Maximum likelihood estimates of linear dynamical systems. <i>AIAA Journal</i> 3, 1445–1450. 15. Quinlan, J. R. (1986). Induction of decision trees. <i>Machine Learning</i> 1(1), 81–106.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(21)

I. Identificación			
Módulo	6	Nombre:	Introducción a la Redes Neuronales
Semestre	2	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA05	Código	MSCIA06
II. Fundamentación	En 1958 Rosenblatt elabora el modelo de red neuronal llamada perceptrón, dicho modelo estaba formado por una única neurona artificial que posee una salida binaria y que es capaz de variar sus pesos y resolver problemas lineales. Sin embargo, en la actualidad las redes neuronales son una de las técnicas con mayor número y variedad de aplicaciones a todos los campos de la ciencia, la ingeniería, la medicina, la arquitectura. A diario aparecen en los medios de comunicación noticias que relacionan a las redes neuronales con aplicaciones novedosas, sorprendentes y muy prometedoras.		
III. Objetivos	Objetivo General: Introducir a los estudiantes las arquitecturas básicas de las redes neuronales, su entrenamiento y aplicación a problemas de clasificación y regresión. Objetivos Específicos: • Aplicar las redes neuronales a la resolución de problemas de regresión y clasificación. • Identificar los diferentes algoritmos de optimización utilizados para el entrenamiento y el ajuste de hiper-parámetros.		
IV. Contenido	1. Introducción a las Redes Neuronales 2. Arquitecturas básicas 3. Entrenamiento con propagación hacia atrás 4. Clasificación Binaria y Multiclase 5. Regresión y redes recurrentes 6. Métodos de Optimización 7. Optimización de Hiper parámetros		
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		
VII. Actividad Extensión	No Aplica		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(22)

VIII. Bibliografía básica	1. Charu C. Aggarwal. Neural Networks and Deep Learning, Springer 2018. 2. Christopher M. Bishop Neural Networks for Pattern Recognition. Oxford University Press, USA 2005 3. Géron, a. (2019). Hands-on machine learning with scikit-learn, keras, and tensorflow: concepts, tools, and techniques to build intelligent systems. O'reilly media. 4. Aaron Courville, Ian Goodfellow y Yoshua Bengio. Deep learning. 5. Ackley, D. H., Hinton, G. E., and Sejnowski, T. J. (1985). A learning algorithm for Boltzmann machines. Cognitive Science, 9, 147–169. 567, 651 6. Alain, G. and Bengio, Y. (2013). What regularized auto-encoders learn from the datagenerating distribution. In ICLR'2013, arXiv:1211.4246 . 504, 509, 512, 518 7. Alain, G., Bengio, Y., Yao, L., Éric Thibodeau-Laufer, Yosinski, J., and Vincent, P. (2015). GSNs: Generative stochastic networks. arXiv:1503.05571. 507, 709 8. Allen, R. B. (1987). Several studies on natural language and back-propagation. In IEEE First International Conference on Neural Networks, volume 2, pages 335–341, San Diego. 468 9. Anderson, E. (1935). The Irises of the Gaspé Peninsula. Bulletin of the American Iris Society, 59, 2–5. 19 10. Ba, J., Mnih, V., and Kavukcuoglu, K. (2014). Multiple object recognition with visual attention. arXiv:1412.7755. 688
IX. Bibliografía complementaria	1. Bachman, P. and Precup, D. (2015). Variational generative stochastic networks with collaborative shaping. In Proceedings of the 32nd International Conference on Machine Learning, ICML 2015, Lille, France, 6-11 July 2015, pages 1964–1972. 713 2. Bacon, P.-L., Bengio, E., Pineau, J., and Precup, D. (2015). Conditional computation in neural networks using a decision-theoretic approach. In 2nd Multidisciplinary Conference on Reinforcement Learning and Decision Making (RLDM 2015). 445717. 3. Bagnell, J. A. and Bradley, D. M. (2009). Differentiable sparse coding. In D. Koller, D. Schuurmans, Y. Bengio, and L. Bottou, editors, Advances in Neural Information Processing Systems 21 (NIPS'08), pages 113–120. 494 4. Bahdanau, D., Cho, K., and Bengio, Y. (2015). Neural machine translation by jointly learning to align and translate. In ICLR'2015, arXiv:1409.0473. 25, 99, 392, 412, 415, 459, 470, 471 5. Bahl, L. R., Brown, P., de Souza, P. V., and Mercer, R. L. (1987). Speech recognition with continuous-parameter hidden Markov models. Computer, Speech and Language, 2, 219–234. 453 6. Baldi, P. and Hornik, K. (1989). Neural networks and principal component analysis: Learning from examples without local minima. Neural Networks, 2, 53–58. 283 7. Baldi, P., Brunak, S., Frasconi, P., Soda, G., and Pollastri, G. (1999). Exploiting the past and the future in protein secondary structure prediction. Bioinformatics, 15(11), 937–946. 388 8. Baldi, P., Sadowski, P., and Whiteson, D. (2014). Searching for exotic particles in high-energy physics with deep learning. Nature communications, 5, 26 9. Ballard, D. H., Hinton, G. E., and Sejnowski, T. J. (1983). Parallel vision computation. Nature. 447 10. Barlow, H. B. (1989). Unsupervised learning. Neural Computation, 1, 295–311. 144 11. Barron, A. E. (1993). Universal approximation bounds for superpositions of a sigmoidal function. IEEE Trans. on Information Theory, 39, 930–945. 195 12. Bartholomew, D. J. (1987). Latent variable models and factor analysis. Oxford University Press. 486 13. Basilevsky, A. (1994). Statistical Factor Analysis and Related Methods: Theory and Applications. Wiley. 486 14. Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I. J., Bergeron, A., Bouchard, N., and Bengio, Y. (2012). 15. Theano: new features and speed improvements. Deep Learning and Unsupervised Feature Learning NIPS 2012 Workshop. 25, 80, 210, 218, 441



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(23)

I. Identificación			
Módulo	7	Nombre:	Aprendizaje Profundo
Semestre	2	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA06	Código	MSCIA07
II. Fundamentación	Los algoritmos de aprendizaje profundo se han convertido en una tendencia creciente para varias soluciones de software en campos como el procesamiento del lenguaje natural, visión por computador y la robótica, siendo núcleo de tecnologías de gran éxito como Alexa, Google Lens entre otros. En la era del Big Data y de grandes avances en la tecnología del cómputo, estos algoritmos han encontrado el momento propicio para florecer y apuntalar nuevos hitos en el procesamiento de los datos, especialmente debido a su gran capacidad de representación de la información en distintos niveles, donde las características más representativas son extraídas directamente de los datos con mínima participación humana. Para entender el funcionamiento de estos algoritmos es necesario comprender sus principios básicos, la estructura de representación de la información, las arquitecturas de las redes más resaltantes y las estrategias de entrenamiento para obtener el mejor resultado.		
III. Objetivos	Objetivo General: Identificar y aplicar modelos de aprendizaje profundo a diferentes tipos de datos (imagen, texto y audio) aplicados a distintas áreas de la ciencia (medicina, ingeniería, entre otros). Objetivos Específicos: • Desarrollar capacidades de implementar algoritmos basados en aprendizaje de máquina para resolver problemas de las ciencias y la ingeniería de datos utilizando modelos basados en el aprendizaje profundo. • Identificar las principales arquitecturas del estado del arte. • Implementar los algoritmos en plataformas web y/o hardware.		
IV. Contenido	1. Redes Convolucionales 2. Redes Generativas Adversarias 3. Redes Recurrentes 4. Aprendizaje por refuerzo 5. Implementación en sistemas Web, Hardware o Celular		
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.		
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(24)

VII. Actividad Extensión	Ninguna
VIII. Bibliografía básica	1. Jeff Heaton. Artificial intelligence for humans, <i>volume 3: deep learning and neural networks</i> (9781505714340). 2. Aaron Courville, Ian Goodfellow y Yoshua Bengio. Deep learning. 3. Andrew W. Trask - Grokking Deep Learning-Manning (2019) 4. Vasilev, I., Slater, D., Spacagna, G., Roelants, P., & Zocca, V. (2019). Python Deep Learning: Exploring deep learning techniques and neural network architectures with Pytorch, Keras, and TensorFlow. Packt Publishing Ltd. 5. Torres, J. (2020). Python deep learning. Marcombo. 6. Chollet, F. (2021). Deep learning with Python. Simon and Schuster. 7. Bayer, J. and Osendorfer, C. (2014). Learning stochastic recurrent networks. ArXiv-preprints. 262 8. Becker, S. and Hinton, G. (1992). A self-organizing neural network that discovers surfaces in random-dot stereograms. Nature, 355, 161–163. 539 9. Behnke, S. (2001). Learning iterative image reconstruction in the neural abstraction pyramid. Int. J. Computational Intelligence and Applications, 1(4), 427–438. 511 10. Beiu, V., Quintana, J. M., and Avedillo, M. J. (2003). VLSI implementations of threshold logic-a comprehensive survey. Neural Networks, IEEE Transactions on, 14(5), 1217–1243. 446.
IX Bibliografía complementaria	1. Belkin, M. and Niyogi, P. (2002). Laplacian eigenmaps and spectral techniques for embedding and clustering. In T. Dietterich, S. Becker, and Z. Ghahramani, editors, Advances in Neural Information Processing Systems 14 (NIPS'01), Cambridge, MA. MIT Press. 240 2. Belkin, M. and Niyogi, P. (2003). Laplacian eigenmaps for dimensionality reduction and data representation. Neural Computation, 15(6), 1373–1396. 160, 516. 3. Bengio, Y. and Bengio, S. (2000b). Modeling high-dimensional discrete data with multi-layer neural networks. In NIPS 12, pages 400–406. MIT Press. 4. Bengio, Y. and Delalleau, O. (2009). Justifying and generalizing contrastive divergence. Neural Computation, 21(6), 1601–1621. 509, 609. 5. Bengio, Y. and Grandvalet, Y. (2004). No unbiased estimator of the variance of k-fold cross-validation. In S. Thrun, L. Saul, and B. Schölkopf, editors, Advances in Neural Information Processing Systems 16 (NIPS'03), Cambridge, MA. MIT Press, Cambridge. 120 6. Bengio, Y. and LeCun, Y. (2007). Scaling learning algorithms towards AI. In Large Scale Kernel Machines. 18 7. Bengio, Y. and Monperrus, M. (2005). Non-local manifold tangent learning. In L. Saul, Y. Weiss, and L. Bottou, editors, Advances in Neural Information Processing Systems 17 (NIPS'04), pages 129–136. MIT Press. 157, 518 8. Bengio, Y. and S��n��cal, J.-S. (2003). Quick training of probabilistic neural nets by importance sampling. In Proceedings of AISTATS 2003. 465



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(25)

IX Bibliografía complementaria	9. Bengio, Y. and Sénécal, J.-S. (2008). Adaptive importance sampling to accelerate training of a neural probabilistic language model. <i>IEEE Trans. Neural Networks</i>, 19(4), 713–722. 465 10. Bengio, Y., De Mori, R., Flammia, G., and Kompe, R. (1991). Phonetically motivated acoustic parameters for continuous speech recognition using artificial neural networks. In <i>Proceedings of EuroSpeech'91</i>. 23, 454 11. Bengio, Y., De Mori, R., Flammia, G., and Kompe, R. (1992). Neural network-Gaussian mixture hybrid for speech recognition or density estimation. In <i>NIPS 4</i>, pages 175–182. Morgan Kaufmann. 454 12. Bengio, Y., Frasconi, P., and Simard, P. (1993). The problem of learning long-term dependencies in recurrent networks. In <i>IEEE International Conference on Neural Networks</i>, pages 1183–1195, San Francisco. IEEE Press. (invited paper). 398 13. Bengio, Y., Simard, P., and Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. <i>IEEE Tr. Neural Nets</i>. 17, 396, 398, 399, 407 14. Bengio, Y., Ducharme, R., and Vincent, P. (2001). A neural probabilistic language model. In T. K. Leen, T. G. Dietterich, and V. Tresp, editors, <i>NIPS'2000</i>, pages 932–938. MIT Press. 17, 442, 458, 461, 467, 472, 477 15. Bengio, Y., Ducharme, R., Vincent, P., and Jauvin, C. (2003). A neural probabilistic language model. <i>JMLR</i>, 3, 1137–1155. 461, 467, 720
--------------------------------	---

I. Identificación			
Módulo	8	Nombre:	Metodología y gestión de proyectos de investigación
Semestre	2	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA04	Código	MSCIA08
II. Fundamentación	La Metodología de la Investigación Científica es la ciencia que aporta un conjunto de métodos, categorías, leyes y procedimientos que garantizan la solución de los problemas científicos con un máximo de eficiencia. El problema científico, se concreta a través de preguntas e hipótesis, donde las preguntas son expresión de lo desconocido, mientras que las hipótesis son afirmaciones o conjeturas que se hacen para contestar dichas preguntas. Estas deben poseer atributos que posibiliten abordarlas en un trabajo de investigación. De ellos los fundamentales son la especificidad, que sean empíricamente contrastables y la fundamentación científica. De la especificidad con que se hayan declarado las hipótesis y preguntas depende en gran medida el éxito de la investigación. Si una investigación es un intento concreto de resolver cierto problema científico, entonces la misma debe estar en función de una pregunta/hipótesis lo suficientemente específica como para permitir abordarla.		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(26)

III. Objetivos	Objetivo General: Identificar las principales metodologías para plantear, implementar y gestionar de proyectos y trabajos de investigación. Objetivos Específicos: • Desarrollar los conceptos básicos para el desarrollo de una investigación. • Explicar los métodos y la visión del investigador para la resolución de problemas reales. • Implementar soluciones enfocadas a la industria y a la resolución de problemas nacionales. • Modelar y plantear una investigación, así como un proyecto de investigación.
IV. Contenido	1. Ciencia, tecnología e investigación. 2. El investigador. Métodos de Investigación. 3. Investigación en la Industria. 4. Creatividad en la investigación. 5. Difusión y comunicación de la investigación. 6. Proyectos de investigación.
V. Estrategia didáctica	Clases teóricas presenciales y prácticas con el desarrollo de temas de investigación.
VI. Estrategia evaluación	Clases magistrales y laboratorios de programación.
VII. Actividad Extensión	N/A
VIII. Bibliografía básica	1. Hernández-Sampieri, R., & Torres, C. P. M. (2018). Metodología de la investigación (Vol. 4, pp. 310-386). México: McGraw-Hill Interamericana. 2. Sánchez, J. C. (2004). Metodología de la investigación científica y tecnológica. Ediciones Díaz de Santos. 3. Project Management Institute. (2017). Guía de los Fundamentos para la Dirección de Proyectos Guía del PMBOK. Project Management Institute. 4. Martín Mayorga D. La Ciencia en tus manos. La sociedad de la información, págs. 615-634. Edit. Espasa Calpe, S. A., Madrid, 2001. 5. Fernández Durán R. La ciencia en tus manos. Los transportes, págs. 707-744. Edit. Espasa Calpe, S. A., Madrid, 2001. 6. Alario Miguel Á. La ciencia en tus Manos. Los materiales, págs. 746-780. Edit. Espasa Calpe, S. A., Madrid, 2001. 7. Fernández-Galiano L. y Paricio I. La ciencia en tus manos. La Arquitectura y su Construcción, págs. 781-807. Edit. Espasa Calpe, S. A., Madrid, 2001. 8. Asthon W. B., Klavans R. A. Keeping Abreast of Science and Technology. Technical Intelligence for Business, Batelle Press, Columbus, USA, 1997. 9. Escorsa P., Valls J. Tecnología e innovación en la empresa. Dirección y gestión, pág. 74. Edit. UPC, Barcelona, 1997. 10.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(27)

IX. Bibliografía complementaria	1. Palop F., Vicente J.M. Estructura de la vigilancia. Master en Gestión de la Ciencia y la Tecnología, Universidad de Carlos III, Madrid, 1994. 2. Amat N. La documentación y sus tecnologías. Edit. Pirámide, Madrid, 1994. 3. Sancho R. Indicadores bibliométricos utilizados en la Ciencia y en la Tecnología. Revisión bibliográfica, Revista Española de Documentación Científica n.º 13,1990. 4. Escorsa P., Maspons R., Rodríguez M. Mapas tecnológicos, estrategia empresarial y oportunidades de mercado. El caso de los textiles para usos médicos. Boletín Intexter n.o 117, pág. 57, UPC, 2000. 5. Cetron M.V. Technological Forecasting. A Practical Approach. Edit. Gordon & Breach, 1969. 6. Fermin de la Sierra, Estrategia de la innovación tecnológica, pág. 216. Edit. ETS. Ingenieros Industriales de Madrid, 1981. 7. Cámara Oficial de Comercio, Industria y Navegación de Barcelona, Investigación e innovación tecnológica en la industria, pág. 32, Barcelona, 1971. 8. Marquis D.G. The Anatomy of Successful Innovations, National Science Foundation, págs. 29-37, 1977. 9. De la Sierra F. Estrategia de la innovación tecnológica, Edit. Sección de Publicaciones de la ETS Ingenieros Industriales, Madrid, 1981. 10. Lowe J. y Crawford N. Innovation and Technology transfer for the growing firm, Edit. Pergamon Press, Oxford, 1984. 11. Suris J.M. La empresa industrial española ante la Innovación Tecnológica, Edit. Hispano Europea, Barcelona, 1986. 12. Twiss B. Managing Technological Innovation. Edit. Pitman Publishing Limited, London, 1986. 13. Ruiz Gonzalez M. y Mandado Pérez E. La innovación tecnológica y su gestión, Edit. Marcombo S. A., Barcelona, 1989. 14. Escorsa Castell P. Valls Pasola J Tecnología e Innovación en la empresa, Dirección y Gestión, Edicions UPC, Barcelona 1997. 15. Baker N.R. Siegman J. A.H. Rubenstein, IEEE Trans. Eng. Manage. Edit. E-M, December 1967.
---------------------------------	--

I. Identificación			
Módulo	9	Nombre:	Sistemas de Recomendación
Semestre	3	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA05	Código	MSCIA09



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(28)

II. Fundamentación	Muchos sistemas de e-commerce hoy en día funcionan a través de sistemas de recomendación. Para poder desarrollar e implementar dichos sistemas es indispensable conocer los modelos matemáticos que se emplean.
III. Objetivos	Objetivo General: Introducir a los alumnos los sistemas de recomendación, su historia, modelos matemáticos, algoritmos, el problema de la escasez de datos, latent factor models, etc. Objetivos Específicos: - Identificar los problemas que pueden ser planteados como sistemas de recomendación. - Entender los fundamentos matemáticos que sustentan los algoritmos del estado del arte. - Tratar adecuadamente el problema de la escasez de datos.
IV. Contenido	- Introducción a los sistemas de Recomendación - Neighborhood-based collaborative filtering - Model-based collaborative filtering - Content-based recommender systems - Evaluación de sistemas de recomendación
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.
VII. Actividad Extensión	No aplica
VIII. Bibliografía básica	- Aggarwal, Charu C. <i>Recommender systems</i>. Vol. 1. Cham: Springer International Publishing, 2016. - Lü, Linyuan, et al. "Recommender systems." <i>Physics reports</i> 519.1 (2012): 1-49. - Koren, Yehuda, Robert Bell, and Chris Volinsky. "Matrix factorization techniques for recommender systems." <i>Computer</i> 42.8 (2009): 30-37. - Luo, Xin, et al. "An efficient non-negative matrix-factorization-based approach to collaborative filtering for recommender systems." <i>IEEE Transactions on Industrial Informatics</i> 10.2 (2014): 1273-1284. - Ning, Xia, and George Karypis. "Slim: Sparse linear methods for top-n recommender systems." <i>2011 IEEE 11th international conference on data mining</i>. IEEE, 2011. H. Steck. Evaluation of recommendations: rating-prediction and ranking. ACM Conference on Recommender Systems, pp. 213–220, 2013. H. Stormer. Improving e-commerce recommender systems by the identification of seasonal products. Conference on Artificial Intelligence, pp. 92–99, 2007. G. Strang. An introduction to linear algebra. Wellesley Cambridge Press, 2009.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(29)

IX. Bibliografía complementaria	1. N. Srebro, J. Rennie, and T. Jaakkola. Maximum-margin matrix factorization. <i>Advances in neural information processing systems</i>, pp. 1329–1336, 2004. 2. Su and T. Khoshgoftaar. A survey of collaborative filtering techniques. <i>Advances in artificial intelligence</i>, 4, 2009. X. Su, T. Khoshgoftaar, X. Zhu, and R. Greiner. Imputation-boosted collaborative filtering using machine learning classifiers. <i>ACM symposium on Applied computing</i>, pp. 949–950, 2008. 3. X. Su, H. Zeng, and Z. Chen. Finding group shilling in recommendation system. <i>World Wide Web Conference</i>, pp. 960–961, 2005. 4. K. Subbian, C. Aggarwal, and J. Srivasatava. Content-centric flow mining for influence analysis in social streams. <i>CIKM Conference</i>, pp. 841–846, 2013. 5. B. O'Sullivan, A. Papadopoulos, B. Faltings, and P. Pu. Representative explanations for over-constrained problems. <i>AAAI Conference</i>, pp. 323–328, 2007. 6. J. Sun and J. Tang. A survey of models and algorithms for social influence analysis. <i>Social Network Data Analytics</i>, Springer, pp. 177–214, 2011. 7. Y. Sun, J. Han, C. Aggarwal, and N. Chawla. When will it happen?: relationship prediction in heterogeneous information networks. <i>ACM International Conference on Web Search and Data Mining</i>, pp. 663–672, 2012. 8. Y. Sun, R. Barber, M. Gupta, C. Aggarwal, and J. Han. Co-author relationship prediction in heterogeneous bibliographic networks. <i>Advances in Social Networks Analysis and Mining (ASONAM)</i>, pp. 121–128, 2011. 9. D. Sutherland, B. Poczos, and J. Schneider. Active learning and search on low-rank matrices. <i>ACM KDD Conference</i>, pp. 212–220, 2013. 10. P. Symeonidis, A. Nanopoulos, and Y. Manolopoulos. Tag recommendations based on tensor dimensionality reduction. <i>ACM Conference on Recommender Systems</i>, pp. 43–50, 2008. 11. M. Szomszor, C. Cattuto, H. Alani, K. O'Hara, A. Baldassarri, V. Loreto, and V. Servedio. Folksonomies, the semantic web, and movie recommendation. <i>Bridging the Gap between the Semantic Web and Web 2.0</i>, pp. 71–84, 2007. 12. N. Taghipour, A. Kardan, and S. Ghidary. Usage-based web recommendations: a reinforcement learning approach. <i>ACM Conference on Recommender Systems</i>, pp. 113–120, 2007. 13. G. Takacs, I. Pitaszy, B. Nemeth, and D. Tikk. Matrix factorization and neighbor based algorithms for the Netflix prize problem. <i>ACM Conference on Recommender Systems</i>, pp. 267–274, 2008. 14. G. Takacs, I. Pitaszy, B. Nemeth, and D. Tikk. Scalable collaborative filtering approaches for large recommender systems. <i>Journal of Machine Learning Research</i>, 10, pp. 623–656, 2009. 15. J. Tang, X. Hu, and H. Liu. Social recommendation: a review. <i>Social Network Analysis and Mining</i>, 3(4), pp. 1113–1133, 2013. J. Tang, J. Sun, C. Wang, and Z. Yang. Social influence analysis in large-scale networks. <i>ACM KDD Conference</i>, pp. 807–816, 2009.
--	--



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(30)

I. Identificación			
Módulo	10	Nombre:	Series Temporales
Semestre	3	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA06	Código	MSCIA10
II. Fundamentación	Los casos de uso de pronóstico de series de tiempo son sin duda los casos de uso de series de tiempo más comunes, ya que se pueden encontrar en todo tipo de industrias y en varios contextos. Ya sea pronosticando las ventas futuras para optimizar el inventario, prediciendo el consumo de energía para adaptar los niveles de producción o estimando el número de pasajeros de las aerolíneas para garantizar servicios de alta calidad, el tiempo es una variable clave. Sin embargo, lidiar con series de tiempo puede ser un desafío. Los datos, que consisten en secuencias de observaciones registradas a intervalos de tiempo regulares, pueden contener ruido, ser muy desiguales o incluso ser intermitentes según el contexto. Los enfoques tradicionales pueden ser demasiado simplistas y tienden a requerir pasos de procesamiento previo y posterior que consumen mucho tiempo para garantizar resultados de rendimiento satisfactorios. En las últimas décadas, los modelos de aprendizaje profundo han tenido un gran éxito. Su aplicación para casos de uso relacionados con el procesamiento del lenguaje natural (NLP), la clasificación de imágenes o el modelado de audio ha superado constantemente los enfoques tradicionales y ha alterado los hábitos comerciales. En cuanto a la previsión de series temporales, muchos trabajos de investigación han aplicado con éxito métodos de aprendizaje profundo. Han propuesto modelos que pueden no solo superar los problemas encontrados con los enfoques estadísticos, sino también manejar mejor la complejidad del pronóstico de series de tiempo y, por lo tanto, obtener resultados significativamente mejorados.		
III. Objetivos	Objetivo General: Conocer los modelos del estado del arte para la predicción, clasificación y detección de anomalías de series temporales Objetivos Específicos: • Identificar los principales modelos estadísticos utilizados para predecir series temporales. • Conocer los modelos de aprendizaje profundo aplicables a series temporales. • Implementar los modelos para resolver problemas de predicción y clasificación de series temporales.		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(31)

IV. Contenido	1. Introducción a las series temporales 2. Modelos estadísticos para predicción 3. Categorización de series temporales 4. Modelos de aprendizaje de máquina tradicionales aplicados a series temporales 5. Predicción y clasificación de series temporales a gran escala con aprendizaje profundo
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.
VII. Actividad Extensión	Ninguna
VIII. Bibliografía básica	1. Lazzeri, F. (2020). Machine learning for time series forecasting with Python. John Wiley & Sons. 2. Auffarth, B. (2021). Machine Learning for Time-Series with Python: Forecast, Predict, and Detect Anomalies with State-of-the-Art Machine Learning Methods. 3. Peixeiro, M. (2022). Time Series Forecasting in Python. Manning. 4. Gridin, I. (2021). Time Series Forecasting using Deep Learning: Combining PyTorch, RNN, TCN, and Deep Neural Network Models to Provide Production-Ready Prediction Solutions (English Edition). BPB Publications. 5. Shumway, R. H., & Stoffer, D. S. (2017). Time series analysis and its applications : with R examples. Springer. 6. Lara-Benítez, P., Carranza-García, M., & Riquelme, J. C. (2021). An experimental review on deep learning architectures for time series forecasting. International Journal of Neural Systems, 31(03), 2130001. 7. Bianchi, Filippo Maria, and Enrico Maiorino, Michael Kampffmeyer, Antonello Rizzi, Robert Jenssen. 2018. Recurrent Neural Networks for Short-Term Load Forecasting. Berlin, Germany: Springer. 8. Brownlee, Jason. 2017. Introduction to Time Series Forecasting With Python - Discover How to Prepare Data and Develop Models to Predict the Future. Machine Learning Mastery. https://machinelearningmastery.com/introduction-to-time-series-forecasting-with-python/ . 9. Che, Zhengping, and Sanjay Purushotham, Kyunghyun Cho, David Sontag, Yan Liu. 2018. "Recurrent Neural Networks for Multivariate Time Series with Missing Values." Scientific Reports 8. https://doi.org/10.1038/s41598-018-24271-9 . 10. Cheng H., Tan PN., Gao J., Scripps J. 2006. "Multistep-Ahead Time Series Prediction." In: Ng WK., Kitsuregawa M., Li J., Chang K. (eds) Advances in Knowledge Discovery and Data Mining, PAKDD 2006. Lecture Notes in Computer Science 3918. Berlin, Heidelberg: Springer. https://doi.org/10.1007/11731139_89 .
IX. Bibliografía complementaria	1. Cho, Kyunghyun, and Bart van Merriënboer, Caglar Gulcehre, Fethi Bougares, Holger Schwenk, Y Bengio. 2014. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. https://doi.org/10.3115/v1/D14-1179 . 2. Glen, Stephanie. 2014. "Endogenous Variable and Exogenous Variable: Definition and Classifying." Statistics How To blog. https://www.statisticshowto.com/endogenous-variable/ .



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(32)

IX. Bibliografía complementaria	3. Lazzeri, Francesca. 2019a. "3 reasons to add deep learning to your time series toolkit." O'Reilly Ideas blog. https://www.oreilly.com/content/3-reasons-to-add-deep-learning-to-your-time-series-toolkit/. 4. Lazzeri, Francesca. 2019b. "Data Science Mindset: Six Principles to Build Healthy Data-Driven Organizations." InfoQ blog. https://www.infoq.com/articles/data-science-organization-framework. 5. Lazzeri, Francesca. 2019c. "How to deploy machine learning models with Azure Machine Learning." Educative.io blog. https://www.educative.io/blog/how-to-deploy-your-machine-learning-model. 6. Lewis-Beck, Michael S., and Alan Bryman, Tim Futing Liao. 2004. The Sage Encyclopedia of Social Science Research Methods. Thousand Oaks, Calif: Sage. 7. Nguyen, Giang, and Stefan Dlugolinsky, Martin Bobak, Viet Tran, Alvaro Lopez Garcia, Ignacio Heredia, Peter Malík, Ladislav Hluchý. 2019. "Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey". Artificial Intelligence Review 52: 77–124. https://doi.org/10.1007/s10462-018-09679-z. 8. Petris, G., and S. Petrone, P. Campagnoli. 2009. Dynamic Linear Models in R. Springer. 9. Poznyak, T., and J.I.C. Oria, A. Poznyak. 2018. Ozonation and Biodegradation in Environmental Engineering: Dynamic Neural Network Approach. Elsevier Science. 10. Stellwagen, Eric. 2011. "Forecasting 101: A Guide to Forecast Error Measurement Statistics and How to Use Them." ForecastPRO blog. https://www.forecastpro.com/Trends/forecasting101August2011.html. 11. Hong, Tao, and Pierre Pinson, Fan Shu, Hamidreza Zareipour, Alberto Troccoli, Rob J. Hyndman. 2016. "Probabilistic Energy Forecasting: Global Energy Forecasting Competition 2014 and Beyond." International Journal of Forecasting 32, no. 3 (July-September): 896–913. 12. Taylor, Christine. 2018. "Structured vs. Unstructured Data." Datamation blog. https://www.datamation.com/big-data/structured-vs-unstructured-data.html. 13. White, Halbert. 1980. "A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity." Econometrica, Econometric Society 48, no.4 (May):817–838. 14. Zhang, Ruiyang, and Zhao Chen, Chen Su, Jingwei Zheng, Oral Büyükoztürk, Hao Sun. 2019. "Deep long short-term memory networks for nonlinear structural seismic response prediction." Computers & Structures 220: 55–68. https://doi.org/10.1016/j.compstruc.2019.05.006. 15. Zhang Y, and YT Zhang, JY Wang, XW Zheng. 2015. "Comparison of classification methods on EEG signals based on wavelet packet decomposition." Neural Comput Appl 26, no. 5:1217–1225.
---------------------------------	--



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(33)

1. Identificación			
Módulo	11	Nombre:	Algoritmos para Aprendizaje No Supervisado
Semestre	3	Naturaleza	Teórico-práctico
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA05	Código	MSCIA11
2. Fundamentación	El aprendizaje no supervisado es un conjunto de técnicas algorítmicas que toman datos sin categorizar y los clasifica en agrupamientos a través del descubrimiento de patrones en los mismos datos sin ninguna intervención externa al algoritmo. Las capacidades de estos algoritmos para descubrir similitudes y diferencias en la información los hace aptos para el análisis de datos exploratorios, segmentación y categorización de datos, reconocimiento en imágenes, por nombrar algunas aplicaciones. En este curso se presentarán los algoritmos clásicos para aprendizaje no supervisado consistentes en clustering y el análisis de componentes principales (o por sus siglas en inglés PCA). Luego se introducirán técnicas que apuntan a aumentar la eficiencia de los algoritmos de conglomerados y PCA a través de la reducción de la cantidad de datos. En general estas técnicas se conocen como técnicas de dispersión de datos, del inglés <i>sparse techniques</i>. Este curso hará énfasis en tres técnicas de dispersión de datos, la dispersión espectral de grafos y matrices, <i>sketching</i> y <i>compressed sensing</i>. Luego se mostrará como estas técnicas se aplican a clustering y PCA de manera a mejorar los tiempos de cómputos con una poca afectación en la calidad de las soluciones.		
3. Objetivos	Objetivo General: Proporcionar fundamentos sobre técnicas avanzadas de aprendizaje no supervisado. Objetivos Específicos: • Comprender el funcionamiento de clustering como un algoritmo de aproximación. • Comprender los fundamentos matemáticos del análisis de componentes principales. • Comprender los algoritmos de dispersión espectral de grafos y su aplicación a clustering y PCA. • Aplicar técnicas básicas de sketching en el análisis de datos. • Introducir la técnica de compressed sensing y su aplicación en el análisis de datos.		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(34)

4. Contenido	1. Clustering. 2. Principal Component Analysis. 3. Spectral Sparsification. 4. Sketching. 5. Compressed sensing.
5. Estrategia didáctica	Clases magistrales y laboratorios de programación.
6. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.
7. Actividad Extensión	Ninguna
8. Bibliografía básica	1. Woodruff, D. P. (2014). Sketching as a tool for numerical linear algebra. Foundations and Trends® in Theoretical Computer Science, 10(1–2), 1-157. 2. Spielman, D. (2019). Spectral and Algebraic Graph Theory. http://cs-www.cs.yale.edu/homes/spielman/sagt/ 3. Bhatia, R. (2013). Matrix analysis (Vol. 169). Springer Science & Business Media. 4. Von Luxburg, U. (2007). A tutorial on spectral clustering. Statistics and computing, 17(4), 395-416. 5. Jolliffe, I. T. (2002). Principal component analysis for special types of data (pp. 338-372). Springer New York. 6. Mendoza-Granada, F., & Villagra, M. (2021). A Distributed Algorithm for Spectral Sparsification of Graphs with Applications to Data Clustering. In Graphs and Combinatorial Optimization: from Theory to Applications (pp. 403-413). Springer, Cham. 7. Mercado, S., & Villagra, M. (2022). Bounds on the spectral sparsification of symmetric and off-diagonal nonnegative real matrices. Discrete Mathematics, Algorithms and Applications, 14(02), 2150109. 8. Spielman, D. A., & Srivastava, N. (2008, May). Graph sparsification by effective resistances. In Proceedings of the fortieth annual ACM symposium on Theory of computing (pp. 563-568). 9. Wickman, R., Zhang, X., & Li, W. (2021). Sparri: Graph sparsification via deep reinforcement learning. arXiv preprint arXiv:2112.01565. 10. Batson, J., Spielman, D. A., Srivastava, N., & Teng, S. H. (2013). Spectral sparsification of graphs: theory and algorithms. Communications of the ACM, 56(8), 87-94.
IX. Bibliografía complementaria	1. Goranci, G. (2019). Dynamic graph algorithms and graph sparsification: New techniques and connections. arXiv preprint arXiv:1909.06413. 2. Czumaj, A., Davies, P., & Parter, M. (2021). Graph sparsification for derandomizing massively parallel computation with low space. ACM Transactions on Algorithms (TALG), 17(2), 1-27.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(35)

IX Bibliografía complementaria	3. Yu, S., Alesiani, F., Yin, W., Jenssen, R., & Principe, J. C. (2022). Principle of Relevant Information for Graph Sparsification. arXiv preprint arXiv:2206.00118. 4. Chen, Y., Khanna, S., & Li, H. (2022). On weighted graph sparsification by linear sketching. arXiv preprint arXiv:2209.07729. 5. Zhao, Z., & Feng, Z. (2020). A Unified Spectral Sparsification Framework for Directed Graphs. 6. Wickman, R., Zhang, X., & Li, W. (2021). Sparrl: Graph sparsification via deep reinforcement learning. arXiv preprint arXiv:2112.01565. 7. Laeuchli, J. (2020, May). Fast community detection with graph sparsification. In Pacific-Asia Conference on Knowledge Discovery and Data Mining (pp. 291-304). Springer, Cham. 8. Batjargal, D., Khan, K. U., & Lee, Y. K. (2019). EM-FGS: Graph sparsification via faster semi-metric edges pruning. Applied Intelligence, 49(10), 3731-3748. 9. Feng, Z. (2020). Grass: Graph spectral sparsification leveraging scalable spectral perturbation analysis. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 39(12), 4944-4957. 10. Li, J., Zhang, T., Tian, H., Jin, S., Fardad, M., & Zafarani, R. (2020, May). Sgc: A graph sparsifier based on graph convolutional networks. In Pacific-Asia Conference on Knowledge Discovery and Data Mining (pp. 275-287). Springer, Cham. 11. Lai, M. J., Xie, J., & Xu, Z. (2020). Graph sparsification by universal greedy algorithms. arXiv preprint arXiv:2007.07161. 12. Fung, W. S., Hariharan, R., Harvey, N. J., & Panigrahi, D. (2011, June). A general framework for graph sparsification. In Proceedings of the forty-third annual ACM symposium on Theory of computing (pp. 71-80). 13. Li, J., Zhang, T., Tian, H., Jin, S., Fardad, M., & Zafarani, R. (2022). Graph sparsification with graph convolutional networks. International Journal of Data Science and Analytics, 13(1), 33-46. 14. Mazuran, M., Tipaldi, G. D., Spinello, L., & Burgard, W. (2014, July). Nonlinear Graph Sparsification for SLAM. In Robotics: Science and Systems (pp. 1-8). 15. Spielman, D. A., & Teng, S. H. (2011). Spectral sparsification of graphs. SIAM Journal on Computing, 40(4), 981-1025.
--------------------------------	---

1. Identificación			
Módulo	12	Nombre:	AI aplicada a Robótica
Semestre	3	Naturaleza	Teórico-Computacional
Cantidad de sesiones	15	Carga horaria total	180
Horas de trabajo Directo en Aulas	45	Horas de trabajo independiente	135
Prerrequisito	MSCIA07	Código	MSCIA12

CSU/SG/rar/lmm/amg/arg/mhv



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(36)

II. Fundamentación	Los Vehículos Autónomos (VA) son aquellos que operan con mínima intervención humana para tareas de monitorización de procesos y exploración de entornos. Esto gracias a la reducción de costos de componentes electrónicos y de procesamiento computacional. Para alcanzar sus objetivos deben contar con un sistema de Guía, Navegación y Control (GNC) para determinar el camino a seguir, caracterizar el entorno en el que se encuentra y actuar sobre los propulsores de movimiento. Diferentes técnicas de Inteligencia Artificial pueden ser utilizadas para resolver los desafíos presentes en cada una de estas tareas, como, por ejemplo, la planificación de rutas y la percepción del entorno mediante visión artificial.
III. Objetivos	Objetivo General: Proveer a los alumnos los fundamentos de los principales desafíos que se encuentran actualmente en la robótica, con énfasis en los VA, y cuáles son las técnicas de Inteligencia Artificial que se utilizan para resolver dichos problemas. Específicamente involucra a los sistemas de GNC. Objetivos Específicos: • Identificar los fundamentos necesarios para modelar los vehículos autónomos. • Conocer los principales algoritmos de planificación y navegación de los VA. • Implementar sistemas de control en VA.
IV. Contenido	1. Introducción a la Robótica 2. Fundamentos de Vehículos Autónomos (VA) 3. Modelado de VA 4. Planificación de VA 5. Navegación de VA 6. Control de VA
V. Estrategia didáctica	Clases magistrales y laboratorios de programación.
VI. Estrategia evaluación	Pruebas de evaluación escritas y prácticas.
VII. Actividad Extensión	N/A
VIII. Bibliografía básica	1. Correll, N. (2016). <i>Introduction to Autonomous Robots: Kinematics, Perception, Localization and Planning</i> (2nd ed.). Magellan Scientific. 2. Thrun, S., Burgard, W., & Fox, D. (2005). <i>Probabilistic Robotics</i> (Intelligent Robotics and Autonomous Agents series) (1st ed.). The MIT Press. 3. Corke, P. I., & Khatib, O. (2011). <i>Robotics, vision and control: fundamental algorithms in MATLAB</i> (Vol. 73, p. 2). Berlin: Springer. 4. LaValle, S. M. (2006). <i>Planning algorithms</i>. Cambridge university press. 5. Choset, H., Lynch, K. M., Hutchinson, S., Kantor, G. A., & Burgard, W. (2005). <i>Principles of robot motion: theory, algorithms, and implementations</i>. MIT press. 6. Wahde, M. (2012). <i>Introduction to autonomous robots</i>. Lecture Notes from the course Autonomous Agents, Chalmers university of technology. 7. Siciliano, B., Khatib, O., & Kröger, T. (Eds.). (2016). <i>Springer handbook of robotics</i>. Springer cham 8. Joseph, L. (2018). <i>Robot operating system (ros) for absolute beginners</i>. Springer.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(37)

VIII Bibliografía básica	9. Quan, Q., Dai, X., & Wang, S. (2020). <i>Multirotor Design and Control Practice: A Series Experiments Based on MATLAB and Pixhawk</i>. Springer Nature. 10. Sakai, A., Ingram, D., Dinius, J., Chawla, K., Raffin, A., & Paques, A. (2018). <i>Pythonrobotics: a python code collection of robotics algorithms</i>. arXiv preprint arXiv:1808.10703.
IX. Bibliografía complementaria	1. Labbe Jr, R. R. (2022). Kalman and Bayesian Filters in Python. https://github.com/rlabbe/Kalman-and-Bayesian-Filters-in-Python 2. Joseph, L., & Caccace, J. (2018). <i>Mastering ROS for Robotics Programming: Design, build, and simulate complex robots using the Robot Operating System</i>. Packt Publishing Ltd. 3. Cass, S. (2020). Nvidia makes it easy to embed AI: The Jetson nano packs a lot of machine-learning power into DIY projects-[Hands on]. <i>IEEE Spectrum</i>, 57(7), 14-16. 4. Süzen, A. A., Duman, B., & Şen, B. (2020, June). Benchmark analysis of jetson tx2, jetson nano and raspberry pi using deep-cnn. In <i>2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)</i> (pp. 1-5). IEEE. 5. Nowak, M. M., Dziób, K., & Bogawski, P. (2018). Unmanned Aerial Vehicles (UAVs) in environmental biology: A review. <i>European Journal of Ecology</i>, 4(2), 56-74. 6. Liu, Y., Dai, H. N., Wang, Q., Shukla, M. K., & Imran, M. (2020). Unmanned aerial vehicle for internet of everything: Opportunities and challenges. <i>Computer communications</i>, 155, 66-83. 7. Yao, H., Qin, R., & Chen, X. (2019). Unmanned aerial vehicle for remote sensing applications—A review. <i>Remote Sensing</i>, 11(12), 1443. 8. Rahman, M. F. F., Fan, S., Zhang, Y., & Chen, L. (2021). A comparative study on application of unmanned aerial vehicle systems in agriculture. <i>Agriculture</i>, 11(1), 22. 9. Peng, Z., Wang, J., Wang, D., & Han, Q. L. (2020). An overview of recent advances in coordinated control of multiple autonomous surface vehicles. <i>IEEE Transactions on Industrial Informatics</i>, 17(2), 732-745. 10. Vagale, A., Oucheikh, R., Bye, R. T., Osen, O. L., & Fossen, T. I. (2021). Path planning and collision avoidance for autonomous surface vehicles I: a review. <i>Journal of Marine Science and Technology</i>, 1-15. 11. Jorge, V. A., Granada, R., Maidana, R. G., Jurak, D. A., Heck, G., Negreiros, A. P., ... & Amory, A. M. (2019). A survey on unmanned surface vehicles for disaster robotics: Main challenges and directions. <i>Sensors</i>, 19(3), 702. 12. Bonadies, S., & Gadsden, S. A. (2019). An overview of autonomous crop row navigation strategies for unmanned ground vehicles. <i>Engineering in Agriculture, Environment and Food</i>, 12(1), 24-31. 13. Moud, H. I., Shojaei, A., & Flood, I. (2018, April). Current and future applications of unmanned surface, underwater, and ground vehicles in construction. In <i>Proceedings of the Construction Research Congress</i> (pp. 106-115). 14. Guastella, D. C., & Muscato, G. (2020). Learning-based methods of perception and navigation for ground vehicles in unstructured environments: A review. <i>Sensors</i>, 21(1), 73. 15. Balestrieri, E., Daponte, P., De Vito, L., & Lamonaca, F. (2021). Sensors and measurements for unmanned systems: An overview. <i>Sensors</i>, 21(4), 1518.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(38)

I. Identificación			
Módulo	13	Nombre:	Investigación Orientada para la Tesis de Maestría
Semestre:	4	Naturaleza:	Teórico-práctico
Cantidad de sesiones	N/A	Carga horaria total	180
Horas de trabajo Directo en Aulas	N/A	Horas de trabajo independiente	N/A
Prerrequisito:	MSCIA09 MSCIA10 MSCIA11 MSCIA12	Código:	MSCIA13
II. Fundamentación:	La presentación de la Tesis es requisito obligatorio para la obtención del Título de Maestría		
III. Objetivos:	Elaborar la tesis de maestría mediante el desarrollo y/o aplicación de técnicas de Inteligencia Artificial a un problema de las ciencias y/o la ingeniería.		
IV. Contenido:	El contenido será definido en anteproyecto de investigación que debe ser presentado durante el desarrollo del módulo MSCIA08.		
V. Estrategia didáctica:	Trabajo individual con tutoría. Se realizan reuniones semanales para el control de avance de la investigación y la elaboración de artículos científicos. Los resultados de las investigaciones realizadas son presentados en congresos regionales y/o internacionales arbitrados por pares.		
VI. Estrategia Evaluación:	El libro de tesis y la presentación final de la tesis se evalúan con siguiente ponderación: Texto de la tesis: 70% Defensa ante mesa de evaluadores: 30%		
VII. Actividad Extensión:	No Aplica		
VIII. Bibliografías:	Según el contenido de cada tesis desarrollada por el alumno		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(39)

I. Identificación			
Módulo	14	Nombre:	Extensión Universitaria
Semestre:	-	Naturaleza:	Teórico-práctico
Cantidad de sesiones	N/A	Carga horaria total	180
Horas de trabajo Directo en Aulas	N/A	Horas de trabajo independiente	N/A
Prerrequisito:		Código:	MSCIA14
II. Fundamentación:	La extensión, función esencial de la universidad, es el conjunto de actividades que la institución realiza más allá del desenvolvimiento los programas de posgrado y de la investigación. De forma general el registro, realización y control de estas actividades se realizan mediante el Departamento de Extensión Académica de la FIUNA.		
III. Objetivos:	Divulgar los resultados de las investigaciones e implementar de proyectos colaborativos con el gobierno y la industria con el fin de mejorar la calidad de vida de la sociedad.		
IV. Contenido:	Las actividades de extensión universitaria aquellas actividades académicas que tienen por objeto promover el desarrollo científico y tecnológico divulgando los resultados de la investigación realizadas; con el fin de crear una colaboración entre la Universidad, la industria, el gobierno y la Sociedad.		
V. Estrategia didáctica:	No Aplica		
VI. Estrategia Evaluación:	Se registran las horas dedicadas a organizar, preparar y presentar los trabajos en las exposiciones de trabajos.		
VII. Actividad Extensión:	Cada semestre se realizan exposiciones de trabajos de investigaciones y por otro lado de invita a profesionales del área de ciencia de datos que se desempeñan tanto en el sector público como privado para identificar las posibles oportunidades de colaboración.		
VIII. Bibliografías:	Según el contenido de cada tesis desarrollada por el alumno		



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(40)

4.2.21. Calendario de desarrollo del programa

Módulo/Actividad	Denominación	Mes Inicio-Año
Módulo 1	Álgebra Lineal Avanzada	Mes 2- Año 1
Módulo 2	Probabilidad y Estadística Avanzada	Mes 3- Año 1
Módulo 3	Programación para análisis de datos	Mes 4- Año 1
Módulo 4	Almacenamiento y procesamiento de datos a gran escala	Mes 5- Año 1
Módulo 5	Aprendizaje de máquina	Mes 7- Año 1
Módulo 6	Introducción a las redes neuronales	Mes 8- Año 1
Módulo 7	Aprendizaje profundo	Mes 9- Año 1
Módulo 8	Metodología y gestión de proyectos de investigación	Mes 10- Año 1
Módulo 9	Sistemas de recomendación	Mes 2- Año 2
Módulo 10	Series temporales	Mes 3- Año 2
Módulo 11	Algoritmos para aprendizaje no supervisado	Mes 4- Año 2
Módulo 12	AI aplicada a Robótica	Mes 5- Año 2
Módulo 13	Investigación Orientada para la Tesis de Maestría	Mes 6 al 12 - Año 2
Módulo 14	Extensión Universitaria	Mes 1- Año 1 al Mes 12 Año 2

4.2.22. Régimen de aplicación de las horas de prácticas

En cada módulo se aplican $\frac{2}{3}$ (30) de las horas de 45 HTD para el desarrollo de ejemplos prácticos de algoritmos y modelos para resolver problemas de aplicación multidisciplinarios.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(41)

4.2.23. Convenios específicos y actualizados

NO APLICA

4.2.24. Modelo pedagógico de la institución

La propuesta pedagógica de la Facultad de Ingeniería de la Universidad Nacional de Asunción y de la Maestría en Ciencias se caracteriza por ser abierta, interdisciplinaria, dialógica, desde la cual promueve el debate y la postura crítica; es decir, se ubica en una perspectiva problematizadora, comprometida con los procesos de cambio y de construcción de nuevos sujetos sociales.

4.2.25. Metodológica general de la institución

El método de enseñanza utilizado en la Universidad Nacional de Asunción está enfocado en formar profesionales competentes, innovadores, éticos y socialmente responsables comprometidos con la promoción de la cultura a través de la enseñanza de calidad, así como la creación, aplicación y difusión del conocimiento orientados al bienestar de la sociedad. En la mayor parte de las facultades se aplican las clases magistrales de forma tradicional. Pero en los cursos de postgrado normalmente las metodologías de enseñanza se combinan con las metodologías alternativas contemporáneas como el Aprendizaje Cooperativo, el Aprendizaje Basado en Proyectos y los Estudios de Casos. La propuesta se sustenta principalmente en el documento denominado Política de la Universidad Nacional de Asunción, Resolución 02-00-2021, donde se definen los lineamientos de la Política de Educativa, y las líneas de acción respecto a la optimización de los procesos de enseñanza (Punto 24).

4.2.26. Metodológica del aprendizaje

El curso de Maestría se desarrollará en formato presencial y virtual. Para la consecución de los objetivos propuestos y el desarrollo de las competencias definidas en el Perfil de Egreso, la Metodología a emplearse en la impartición del curso plantea las siguientes modalidades:

- Clases magistrales y ejercicios que implementan el aprendizaje basado en proyectos;
- Laboratorios donde se utilizan herramientas computacionales;
- Videoconferencias y Seminarios;
- Tutorías de tesis.

4.2.27. Sistema de Evaluación general institucional

El Sistema de Evaluación de cada asignatura del Programa será determinado por el Profesor de cada asignatura y deberá contar con la aprobación del coordinador del Programa. Las evaluaciones podrán implementarse mediante instrumentos de evaluación como: exámenes, cuestionarios, estudios de casos, trabajos prácticos, lista de ejercicios, análisis de artículos científicos, etc. Para aprobar un determinado módulo se requiere un puntaje mínimo del 60%. En caso que no se alcance el mínimo requerido, se tendrá una segunda oportunidad para aprobar el módulo. Al finalizar los 12 módulos se calculará el promedio de los 12 puntajes. La escala de evaluación, para la valoración de las evaluaciones de los módulos se hará conforme se especifica en el Reglamento General de Postgrado de la UNA, bajo resolución de la Universidad Nacional de Asunción Res N° 264-00-2015, en su Artículo 21 incisos c) y d), de conformidad a la siguiente escala.

CSU/SG/rar/lmm/amg/arg/mhv



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(42)

SITUACIÓN ACADÉMICA	PUNTUACIÓN	NOTA	CALIFICACIÓN
Reprobado:	0-59%	1 (Uno)	Insuficiente
Aprobado:	60-69%	2 (Dos)	Regular
	70-79%	3 (Tres)	Bueno
	80-90%	4 (Cuatro)	Distinguido
	91-100%	5 (Cinco)	Sobresaliente

4.2.28. Sistema de Evaluación del programa

El programa será evaluado mediante indicadores, tales como la cantidad de egresados y cantidad de artículos publicados en congresos y revistas científicas indexadas.

4.2.29. Sistema de evaluación de la Investigación

La investigación de la maestría será evaluada por un jurado compuesto por los menos de 3 miembros que fueron tutores del estudiante en cuestión. Los miembros del jurado tienen que tener por lo menos el grado de máster. Se evaluarán el trabajo escrito por un evaluador y la defensa del mismo por otro lado teniendo la parte escrita un peso de 60% y la defensa 40%. La evaluación será individual y el puntaje final se calcula como promedio de los puntajes parciales de los integrantes del jurado.

4.2.30. Investigación y relación del programa con las líneas de investigación de la IES

Las líneas de investigación se enmarcan principalmente una de las líneas de investigación más recientes en la Facultad de Ingeniería (FIUNA) que se centra en la aplicación de desarrollo de técnicas de Inteligencia Artificial (IA) en múltiples áreas de la ciencia, como robótica, agricultura de precisión, sistemas embebidos, bioelectrónica y biología computacional. Las demás líneas declaradas en el apartado correspondiente 4.2.32 están coordinadas por docentes investigadores y grupos de trabajo de nuestra casa de estudio que ya cuentan con publicaciones en sus respectivas áreas de actuación.

Los resultados de las investigaciones realizadas con los estudiantes y docentes serán publicados en eventos regionales e internacionales del área de interés de cada trabajo. Los algoritmos, códigos para la reproducción del trabajo y datos (en caso de que sean públicos) podrán publicados en repositorios para maximizar el impacto de los trabajos publicados. También se tienen los eventos de divulgación científica institucional y nacional que permitan divulgar los resultados con la audiencia general que incluye otras estudiantes y representantes de otras instituciones académicas, así como la industria.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(43)

Además, debido a la relevancia contemporánea de la inteligencia artificial se espera también el apoyo de los medios de prensa escritos y digitales.

Los seminarios realizados por los estudiantes que se encuentren en los últimos semestres serán abiertos para estudiantes de grado y docentes interesados de tal forma fomentar la sinergia entre los grupos de investigación. Los talleres de investigación permitirán incentivar el vínculo con el gobierno y/o empresas privadas y/o otros grupos de investigadores, se esperan publicaciones conjuntas en el mediano plazo.

El comité científico designará un tutor académico a cada estudiante de acuerdo a los cupos disponibles en cada línea de investigación, la línea de interés de estudiantes y al financiamiento disponible para cada uno. Los tutores académicos supervisarán las actividades de investigación y ayudarán a publicar los trabajos en congresos nacionales e internacionales de relevancia. También serán responsables por la revisión rigurosa de la tesis de maestría que posteriormente será evaluada en la defensa final.

4.2.31. Sistema de evaluación de Extensión

La dirección de extensión registrará las actividades de extensión realizadas por los estudiantes y los docentes del proyecto académico. Descripción de líneas de investigación.

4.2.32. Descripción de Investigación



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py
C. Elect.: sgeneral@rec.una.py
Telefax: 595 – 21 – 585540/3, 585546
CP: 2160, San Lorenzo – Paraguay
Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../..(44)

TABLA 3. LÍNEAS DE INVESTIGACIÓN

Área de investigación y descripción del área	Líneas de investigación	Proyectos de investigación activos o en desarrollo	Responsable de línea y categorización	Tutor/cotutor y categorización	Carga horaria tutoría	Número de plazas para estudiantes del programa
<u>Sistemas de Automatización:</u> Esta área comprende todos los sistemas electrónicos desplegados para la realización de tareas de manera autónoma en distintos campos. Abarca el estudio de los componentes de hardware, middleware y software para la implementación de dichos sistemas	Sistemas Distribuidos	N/A	Derlis Gregor, Ph.D.	Marcos Villagra, Ph.D.	2	2
	Sistemas Inteligentes de Transporte	N/A	Derlis Gregor, Ph.D.	Maira Santacruz, MSc.	2	2
	Sistemas de Monitoreo y Gestión del Medioambiente	N/A	Maira Santacruz, MSc.	Derlis Gregor, Ph.D.	2	2



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py
C. Elect.: sgeneral@rec.una.py
Telefax: 595 – 21 – 585540/3, 585546
CP: 2160, San Lorenzo – Paraguay
Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(45)

Área de investigación y descripción del área	Líneas de investigación	Proyectos de investigación activos o en desarrollo	Responsable de línea y categorización	Tutor/cotutor y categorización	Carga horaria tutoría	Número de plazas para estudiantes del programa
<u>Vehículos autónomos:</u> Los vehículos autónomos se refieren a aquellos que operan con mínima intervención humana. Se utilizan actualmente para tareas de monitoreo, seguridad, vigilancia entre otros. Los principales desafíos del área se centran en el desarrollo de algoritmos de guía, navegación y control.	Drones terrestres y acuáticos	N/A	Mario Arzamendia, Ph.D.	Jorge Rodas, Ph.D.	2	2
	Drones aéreos	N/A	Jorge Rodas, Ph.D.	Mario Arzamendia, Ph.D.	2	2
<u>Sistemas complejos:</u> Se refiere a los sistemas compuestos por varios bloques relacionados entre sí y que poseen un comportamiento no-lineal desconocido. Posee aplicaciones en distintas áreas del conocimiento tales como matemática, teoría de la información, economía, etc.	Optimización Computacional	N/A	Marcos Villagra, Ph.D.	Inocencio Ruiz, Ph.D.	2	2



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py
C. Elect.: sgeneral@rec.una.py
Telefax: 595 – 21 – 585540/3, 585546
CP: 2160, San Lorenzo – Paraguay
Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../..(46)

Área de investigación y descripción del área	Líneas de investigación	Proyectos de investigación activos o en desarrollo	Responsable de línea y categorización	Tutor/cotutor y categorización	Carga horaria tutoría	Número de plazas para estudiantes del programa
<u>Ciencia de datos</u> : Se refiere al área que estudia cómo interpretar y obtener conocimiento a partir de los grandes volúmenes de datos que se generan actualmente. Abarca las técnicas de procesamiento y visualización de información relevante de manera concisa.	Minería de datos	N/A	Diego Palacios, MSc.	Leonardo Jara, MSc.	2	2
<u>Aprendizaje de máquina</u> : Es un nuevo paradigma de programación de computadores para generar modelos de interpretación y predicción de datos. En vez de programar un modelo de sistema, los algoritmos de aprendizaje de máquina	Series Temporales	N/A	Diego Stalder, Ph.D.	Diego Galeano, Ph.D.	2	2



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py
C. Elect.: sgeneral@rec.una.py
Telefax: 595 – 21 – 585540/3, 585546
CP: 2160, San Lorenzo – Paraguay
Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../..(47)

Área de investigación y descripción del área	Líneas de investigación	Proyectos de investigación activos o en desarrollo	Responsable de línea y categorización	Tutor/cotutor y categorización	Carga horaria tutoría	Número de plazas para estudiantes del programa
generan estos modelos a partir de los datos analizados. Luego estos modelos pueden ser utilizados para realizar predicciones, clasificaciones o interpretación de datos históricos.	Sistemas de recomendación	N/A	Diego Galeano, Ph.D.	Diego Stalder, Ph.D.	2	2
	Biología computacional	N/A	Diego Galeano, Ph.D.	José Colbes, Ph.D.	2	2
<u>Visión computacional</u> : Es el área que se dedica a la extracción de información a partir de imágenes digitales. Actualmente es una de las principales áreas de desarrollo dentro de la inteligencia artificial gracias a las teorías referentes a las redes neuronales y aprendizaje profundo.	Redes profundas	N/A	Luis Salgueiro, Ph.D.	Mario Arzamendia, Ph.D.	2	2

../..(48)

4.2.33. Actividades de extensión relacionadas

Cada investigador a cargo de un estudiante del programa de Maestría asesorará al estudiante para la potencial divulgación de los resultados de la tesis de Maestría, siempre que esta sea considerada de relevancia en el ámbito de la ingeniería e investigación.

4.2.34. Características de la tesis de postgrado

Cada estudiante realizará un trabajo individual desarrollando un estudio de caso de una aplicación concreta según las líneas de investigación definidas. El reporte escrito final deberá contener los siguientes ítems:

- Introducción con justificación, objetivos y alcance.
- Marco teórico con el estado del arte.
- Planteamiento del Problema.
- Metodología.
- Resultados.
- Conclusiones.
- Bibliografía.

4.2.35. Programas de actividades académicas:

En esta sección se presentan los programas de cada una de las actividades académicas.



"Tradición y Excelencia en la formación de Ingenieros"

UNIVERSIDAD NACIONAL DE ASUNCIÓN

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../..(49)

Código	MSCIA01
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	PRIMER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Algebra Lineal Avanzada
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	-

1. Fundamentación:

El álgebra lineal es el estudio de los espacios vectoriales y de sus transformaciones. El concepto de espacio vectorial es omnipresente en la ciencia moderna, y la razón es simple de apreciar. En primer lugar, ofrece una aproximación para el estudio de sistemas complejos no lineales, recurrentes en las ciencias e ingeniería mediante el modelamiento matemático de fenómenos y procesos. En segundo lugar, proporciona el cimiento conceptual para disciplinas de elevado nivel práctico como el álgebra de matrices, métodos numéricos, análisis vectorial, optimización entre otros. En particular, se ha convertido en uno de los pilares matemáticos de la ciencia de datos, al proporcionar el lenguaje apropiado para la automatización y el aprendizaje de máquina.

2. Objetivo General:

Proporcionar el cimiento conceptual de álgebra lineal avanzada para disciplinas de elevado nivel práctico como el álgebra de matrices, métodos numéricos, análisis vectorial y la optimización.

3. Objetivos Específicos:

- Familiarizar al estudiante con los conceptos de espacio vectorial y sus transformaciones.
- Familiarizar al estudiante con la geometría de los espacios vectoriales.
- Introducir aplicaciones fundamentales de la teoría de espacios vectoriales al álgebra matricial.

Introducir conceptos básicos de análisis vectorial.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(50)

4. **Contenidos:**

1. Espacios vectoriales
2. Transformaciones y matrices
3. Geometría de espacios vectoriales
4. Cálculo vectorial

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Deisenroth, M. P., Faisal, A. A. and Ong, C. S.: Mathematics for Machine Learning. Cambridge University Press, 2020.
2. Meyer, C. D.: Matrix Analysis and Applied Linear Algebra. SIAM, 2000.
3. Strang, G.: Linear Algebra and Learning from Data. Cambridge Press, 2019.
4. Ruffini, Paolo. 1799. Teoria Generale delle Equazioni, in cui si Dimostra Impossibile la
5. Soluzione Algebraica delle Equazioni Generali di Grado Superiore al Quarto. Stamperia di S. Tommaso d'Aquino.
6. Rumelhart, David E., Hinton, Geoffrey E., and Williams, Ronald J. 1986. Learning Representations by Back-Propagating Errors. Nature, 323(6088), 533–536.
7. Sæmundsson, Steindor, Hofmann, Katja, and Deisenroth, Marc P. 2018. Meta Reinforcement Learning with Latent Variable Gaussian Processes. In: Proceedings of the Conference on Uncertainty in Artificial Intelligence.
8. Saitoh, Saburo. 1988. Theory of Reproducing Kernels and its Applications. Longman Scientific and Technical.
9. Sarkka, Simo. 2013. Bayesian Filtering and Smoothing. Cambridge University Press.
10. Mitchell, Tom. 1997. Machine Learning. McGraw-Hill.

Complementarias

1. Scholkopf, Bernhard, and Smola, Alexander J. 2002. " Learning with Kernels – Support
2. Vector Machines, Regularization, Optimization, and Beyond. MIT Press.
3. Scholkopf, Bernhard, Smola, Alexander J., and Müller, Klaus-Robert. 1997. Kernel "
4. Principal Component Analysis. In: Proceedings of the International Conference on Artificial Neural Networks.
5. Scholkopf, Bernhard, Smola, Alexander J., and Müller, Klaus-Robert. 1998. Nonlinear Component Analysis as a Kernel Eigenvalue Problem. Neural Computation, 10(5), 1299–1319.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(51)

6. Scholkopf, Bernhard, Herbrich, Ralf, and Smola, Alexander J. 2001. A Generalized Representer Theorem. In: Proceedings of the International Conference on Computational Learning Theory.
7. Schwartz, Laurent. 1964. Sous Espaces Hilbertiens d'Espaces Vectoriels Topologiques et Noyaux Associés. Journal d'Analyse Mathématique, 13, 115–256.
8. Schwarz, Gideon E. 1978. Estimating the Dimension of a Model. Annals of Statistics, 6(2), 461–464.
9. Shahriari, Bobak, Swersky, Kevin, Wang, Ziyu, Adams, Ryan P., and De Freitas, Nando. 2016. Taking the Human out of the Loop: A Review of Bayesian Optimization. Proceedings of the IEEE, 104(1), 148–175.
10. Shalev-Shwartz, Shai, and Ben-David, Shai. 2014. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press.
11. Shawe-Taylor, John, and Cristianini, Nello. 2004. Kernel Methods for Pattern Analysis. Cambridge University Press.
12. Shawe-Taylor, John, and Sun, Shiliang. 2011. A Review of Optimization Methodologies in Support Vector Machines. Neurocomputing, 74(17), 3609–3618.
13. Shental, Ori, Siegel, Paul H., Wolf, Jack K., Bickson, Danny, and Dolev, Danny. 2008. Gaussian Belief Propagation Solver for Systems of Linear Equations. Pages 1863–1867 of: Proceedings of the International Symposium on Information Theory.
14. Shewchuk, Jonathan R. 1994. An Introduction to the Conjugate Gradient Method without the Agonizing Pain.
15. Shi, Jianbo, and Malik, Jitendra. 2000. Normalized Cuts and Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 22(8), 888–905.



“Tradición y Excelencia en la formación de Ingenieros”

UNIVERSIDAD NACIONAL DE ASUNCIÓN
SEDE, CAMPUS DE LA UNA, SAN LORENZO
FACULTAD DE INGENIERÍA
DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA
PROGRAMA DE ACTIVIDADES ACADÉMICAS
MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(52)

Código	MSCIA02
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	PRIMER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Probabilidad y Estadística avanzada
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	-

1. Fundamentación:

Los modelos de aprendizaje de máquina pueden verse como una extensión de los modelos de inferencia estadísticos. Además que estos modelos de aprendizaje automático se fundamentan en gran medida en la teoría de la probabilidad.

2. Objetivo General:

Proporcionar conceptos de probabilidad y estadística necesarios para entender y proponer nuevos modelos de aprendizaje de máquina.

3. Objetivos Específicos:

- Presentar a los alumnos las principales aplicaciones de la probabilidad y estadística en el aprendizaje de máquina.
- Introducir a los alumnos en los fundamentos probabilísticos del aprendizaje supervisado.

4. Contenidos:

1. Estadística, estimación de parámetros y pruebas de hipótesis usando Python.
2. Visualización de Distribuciones (boxplot, violinplot, etc)
3. Probabilidad y distribuciones usando Python.
4. Estimaciones de parámetros frecuentista versus bayesiana.
5. Introducción a la teoría del aprendizaje estadístico: Riesgo empírico, cotas de error y medidas de capacidad.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(53)

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Downey, Allen B. "Think Stats: Probability and Statistics for Programmers; 2e." (2014).
2. Gareth, James, et al. An introduction to statistical learning: with applications in R. Springer, 2013.
3. Bousquet, Olivier, Stéphane Boucheron, and Gábor Lugosi. "Introduction to statistical learning theory." Summer school on machine learning. Springer, Berlin, Heidelberg, 2003.
4. Vapnik, V.: Statistical Learning Theory. John Wiley, New York (1998)
5. Anthony, M., Bartlett, P.L.: Neural Network Learning: Theoretical Foundations. Cambridge University Press, Cambridge (1999)
6. Breiman, L., Friedman, J., Olshen, R., Stone, C.: Classification and Regression Trees. Wadsworth International, Belmont, CA (1984)
7. Devroye, L., Györfi, L., Lugosi, G.: A Probabilistic Theory of Pattern Recognition. Springer-Verlag, New York (1996)
8. Duda, R., Hart, P.: Pattern Classification and Scene Analysis. John Wiley, New York (1973)
9. Fukunaga, K.: Introduction to Statistical Pattern Recognition. Academic Press, New York (1972)
10. Kearns, M., Vazirani, U.: An Introduction to Computational Learning Theory. MIT Press, Cambridge, Massachusetts (1994).

Complementarias

1. Kulkarni, S., Lugosi, G., Venkatesh, S.: Learning pattern classification—a survey. IEEE Transactions on Information Theory 44 (1998) 2178–2206 Information Theory: 1948–1998. Commemorative special issue.
2. Lugosi, G.: Pattern classification and learning theory. In Györfi, L., ed.: Principles of Nonparametric Learning, Springer, Viena (2002) 5–62
3. McLachlan, G.: Discriminant Analysis and Statistical Pattern Recognition. John Wiley, New York. 1992.
4. von Luxburg, U., Bousquet, O., Scholkopf, B.: A compression approach to support vector model selection. The Journal of Machine Learning Research (2004) 293–323
5. McDiarmid, C.: On the method of bounded differences. In: Surveys in Combinatorics 1989, Cambridge University Press, Cambridge (1989) 148–188



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(54)

6. Vapnik, V., Chervonenkis, A.: On the uniform convergence of relative frequencies of events to their probabilities. Theory of Probability and its Applications 16 (1971) 264–280
7. Hoeffding, W.: Probability inequalities for sums of bounded random variables. Journal of the American Statistical Association 58 (1963) 13–30
8. Ledoux, M., Talagrand, M.: Probability in Banach Space. Springer-Verlag, New York (1991)
9. Sauer, N.: On the density of families of sets. Journal of Combinatorial Theory Series A 13 (1972) 145–147
10. Shelah, S.: A combinatorial problem: Stability and order for models and theories in infinity languages. Pacific Journal of Mathematics 41 (1972) 247–261
11. Alesker, S.: A remark on the Szarek-Talagrand theorem. Combinatorics, Probability, and Computing 6 (1997) 139–144
12. Alon, N., Ben-David, S., Cesa-Bianchi, N., Haussler, D.: Scale-sensitive dimensions, uniform convergence, and learnability. Journal of the ACM 44 (1997) 615–631
13. Cesa-Bianchi, N., Haussler, D.: A graph-theoretic generalization of the SauerShelah lemma. Discrete Applied Mathematics 86 (1998) 27–35
14. Frankl, P.: On the trace of finite sets. Journal of Combinatorial Theory, Series (1983) 41–45
15. Haussler, D.: Sphere packing numbers for subsets of the boolean n-cube with bounded Vapnik-Chervonenkis dimension. Journal of Combinatorial Theory, Series A 69 (1995) 217–232



“Tradición y Excelencia en la formación de Ingenieros”

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(55)

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA03
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	PRIMER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Programación para Análisis de datos
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	-

1. Fundamentación:

Debido a la constante generación y disponibilidad de una gran cantidad de datos, el análisis de estos se ha vuelto imprescindible para obtener información clave para la toma de decisiones en organizaciones.

Por este motivo, resulta indispensable el conocimiento y aplicación de algoritmos basados en la matemática (especialmente en la estadística). Debido a su facilidad de aprendizaje e implementación, y a la gran cantidad de librerías existentes, Python se ha vuelto un lenguaje de programación popular para proyectos de análisis de datos.

2. Objetivo General:

Introducir a los estudiantes a los conceptos claves del lenguaje de Programación Python y su aplicación en aspectos fundamentales del análisis de datos

3. Objetivos Específicos:

- Introducir las funcionalidades nativas del lenguaje Python.
- Presentar las bibliotecas que permitan manipular datos matriciales.
- Conocer las principales bibliotecas de visualización de datos.

4. Contenidos:

1. Principios básicos del lenguaje de programación Python.
2. Ambiente de programación Jupyter.
3. Introducción al análisis de datos.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(56)

4. Utilización de *numpy*.
5. Manejo de datos con *pandas*.
6. Visualización de datos con Python (*matplotlib*, *seaborn*, entre otros).
7. Fundamentos del aprendizaje de máquina e introducción a *scikit-learn*.

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Varó, A. M., Sevilla, P. G., & Luengo, I. G. (2014). Introducción a la programación con Python 3. Universitat Jaume I. Servei de Comunicació i Publicacions.
2. McKinney, W. (2017). Python for data analysis: Data wrangling with Pandas, NumPy, and IPython (2nd Edition). O'Reilly Media, Inc.
- 3.
- 4.
5. VanderPlas, J. (2016). Python data science handbook: Essential tools for working with data. O'Reilly Media, Inc.
6. Cyrille Rossant. IPython Interactive Computing and Visualization Cookbook - Second Edition. Packt. 2018.
7. Eli Bressert. SciPy and NumPy: Optimizing & Boosting your Python Programming. O'Reilly Media, 2012.
8. Rituraj Dixit. Data Analysis with Python: Introducing NumPy, Pandas, Matplotlib, and Essential Elements of Python Programming. BPB Publications. 2023.
9. AI Publishing. Python NumPy for Beginners: NumPy Specialization for Data Science. AI Publishing. 2022.
10. Robert Johansson. Numerical Python: Scientific Computing and Data Science Applications with Numpy, SciPy and Matplotlib. Apress. 2019
11. Rossant, C. IPython Interactive Computing and Visualization Cookbook. Mumbai: Packt. 2014.
12. Devert, A. matplotlib Plotting Cookbook. Mumbai: Packt. 2014.

Complementarias

1. Milovanovi, I. (2013). Python Data Visualization Cookbook. Mumbai: Packt.
2. Tosi, S. (2009). Matplotlib for Python Developers. Mumbai: Packt.
3. Yau, N. (2011). Visualize this. Indianapolis: Wiley.
4. Idris, I. Learning NumPy Array. Mumbai: Packt, 2014.
5. Idris, I. Numpy Beginner's Guide. 3rd. Mumbai: Packt, 2015.
6. Idris, I. NumPy Cookbook. Mumbai: Packt, 2012.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../..(57)

7. Rossant, C. Learning IPython for Interactive Computing and Data Visualization. Mumbai: Packt. 2013.
8. Rance D. Necaise. Data Structures and Algorithms Using Python. Wiley. 2010.
9. Alfred V. Aho, John E. Hopcroft, and Jeffrey D. Ullman. Data Structures and Algorithms. Addison-Wesley, Reading, MA, 1983.
10. John L. Bentley. Programming pearls: How to sort. Communications of the ACM, 27(3):287–291, March 1984.
11. John L. Bentley. Programming pearls: The back of the envelope. Communications of the ACM, 27(3):180–184, March 1984.
12. John L. Bentley. Programming pearls: Thanks, heaps. Communications of the ACM, 28(3):245–250, March 1985.
13. John L. Bentley. Programming Pearls. Addison-Wesley, Reading, MA, 1986.
14. John L. Bentley. Programming pearls: The envelope is back. Communications of the ACM, 29(3):176–182, March 1986.
15. Timothy Budd. Classic Data Structures. Addison-Wesley, Reading, MA, 2001.



“Tradición y Excelencia en la formación de Ingenieros”

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(58)

Código	MSCIA04
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	PRIMER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Almacenamiento y procesamiento de datos a gran escala
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	-

1. Fundamentación:

El avance de la tecnología ha permitido que la adquisición de datos masivos y su almacenamiento sea una realidad, y esto se volvió transversal en todos los aspectos de la vida (economía, ciencias, salud, medio ambiente, etc.). Sin embargo, obtener conocimiento e información relevante de una extensa cantidad de datos se vuelve muy difícil con las técnicas de procesamiento convencionales, es por eso que aparecen nuevas técnicas, conceptos y métodos para la extracción automática de conocimiento a partir de grandes cantidades de datos almacenados, todos ellos enmarcados en el concepto de Data Mining o Big Data, el cual es el objeto de estudio de este curso, y que soluciona problemas reales en el campo de la investigación científica y la vida misma.

2. Objetivo General:

Entrenar a los estudiantes para que sean capaces de extraer conocimiento oculto relevante a partir de una gran cantidad de datos aplicando técnicas computacionales avanzadas de procesamiento de información, para resolver problemas en el campo de las ciencias, la investigación y la ingeniería de datos.

3. Objetivos Específicos:

- Aprender acerca de conceptos relacionados a la Minería de Datos, aplicación de técnicas computacionales avanzadas apropiadas para la adquisición de conocimiento a partir de una extensa base de datos, a gestión, manipulación, almacenamiento y procesamiento de una gran cantidad de datos de calidad.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(59)

- Aplicar las habilidades adquiridas en el desarrollo de un trabajo práctico basado en un problema real de investigación científica.

4. **Contenidos:**

1. Introducción a la Minería de Datos.
2. Teoría de Datos. Tipos. Atributos. Calidad. Preprocesamiento.
3. Exploración de Datos. Visualización. Procesamiento Analítico en Línea (OLAP).
4. Análisis de Clasificación. Conceptos y Técnicas.
5. Análisis de Asociación. Conceptos y Técnicas.
6. Clusterización. Conceptos y Técnicas.

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Pang-Ning Tan, Michael Steinbach, Vipin Kumar. Introduction to Data Mining. Pearson Addison Wesley, 2006.
2. Jiawei Han, Micheline Kamber, Jian Pei. Data Mining: Concepts and Techniques. Third Edition. Morgan Kaufmann, Elsevier. 2012.
3. Charu C. Aggarwal. Data Mining: The Textbook. Springer. 2015.
4. Ian H. Witten, Eibe Frank, Mark A. Hall. Data Mining: Practical Machine Learning Tools and Techniques. Third Edition. Morgan Kaufmann, Elsevier. 2011.
5. David L. Olson, Dursun Delen. Advanced Data Mining Techniques. Springer 2008.
6. J. Hartigan. Clustering Algorithms. Wiley, New York, 1975
7. Stephan Kudyba, Big Data, Mining, and Analytics: Components of Strategic Decision Making. CRC Press. 2014.
8. Eagle, Nathan; Greene, Kate. Reality mining: using big data to engineer a better world. The MIT Press. 2014.
9. Jared Dean. Big Data, Data Mining, and Machine Learning: Value Creation for Business Leaders and Practitioners. Wiley. 2014.
10. Fausto Pedro Garcia Marquez. Handbook of Research on Big Data Clustering and Machine Learning. IGI Global. 2019.

Complementarias

1. Gareth James & Daniela Witten. An Introduction to Statistical Learning: with Applications in R. Springer. 2013



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(60)

2. Foster Provost & Tom Fawcet. Data Science for Business: What you need to know about data mining and data-analytic thinking. O'Reilly Media, Inc. 2013
3. Berkhin, P. Survey of Clustering Data Mining Techniques. Accrue Software. 2002
4. Berman, J. J. Introduction. In Principles of Big Data. Morgan Kaufmann. 2013.
5. Hartigan, J.A. (1975). Clustering algorithms. New York: Wiley.
6. Kass, G.V. (1980). An exploratory technique for investigating large quantities of categorical data. Applied Statistics, 29, 119–127. (Standard reference for the CHAID algorithm Kass described in his 1975 PhD thesis.)
7. McQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In Proceedings of 5th Berkeley Symposium on Mathematical Statistics Probability, vol. 1, pp. 281–297.
8. Neville, P. (1999). Growing trees for stratified modeling. Computing Science and Statistics, 30. (Extends the ideas of Sonquist et al. and Alexander and Grimshaw for more independent variables and more types of models.)
9. Rawlings, J.O. (1988). Applied regression analysis: A research tool. Belmont, CA: Wadsworth.
10. SAS Enterprise Miner 12.1. (2012). On-line reference help. Cary, NC: SAS Institute.
11. Schapire, R. E., and Freund, Y. (2012). Boosting: Foundations and Algorithms. Cambridge, MA: MIT Press.
12. Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. Journal of the Royal
13. Statistical Society B (Methodological), 267–288.
14. Vapnik, V. The nature of statistical learning theory. New York: Springer-Verlag, 1995.
15. Bing-Chao Huang and Michael A. Langston. Practical in-place merging. Communications of the ACM, 31(3):348–352, 1988.



"Tradición y Excelencia en la formación de Ingenieros"

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

CSU/SG/rar/lmm/amg/arg/mhv



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(61)

Código	MSCIA04
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	SEGUNDO SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Aprendizaje de Máquina
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA01 MSCIA02 MSCIA03

1. Fundamentación:

La Inteligencia Artificial (IA) ha surgido como una tendencia tecnológica global líder para el futuro, la cual ha ido evolucionando no solo en el sector de la tecnología, sino también por ejemplo en sectores agrícolas, automotriz, bancario, médico, etc. Mediante una combinación de técnicas de entrenamiento avanzadas y elementos no lineales y estocásticos, ahora es posible desarrollar algoritmos que puedan manejar datos tabulares, imágenes, texto y audio como entrada y salida.

2. Objetivo General:

Desarrollar la capacidad de crear e implementar algoritmos basados en aprendizaje de máquina para resolver problemas de las ciencias y la ingeniería de datos. Analizando los conceptos teóricos para la implementación de algoritmos de IA. Se espera que los estudiantes demuestren la asimilación a través de la realización de un proyecto final integrador.

3. Objetivos Específicos:

- Conocer los principales métodos para implementar el aprendizaje supervisado y no supervisado.
- Implementar Algoritmos de Optimización para ajustar los parámetros e hiper-parámetros de los modelos.
- Identificar las principales métricas de desempeño aplicados los diversos problemas donde se aplica el aprendizaje de máquina.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(62)

4. Contenidos:

1. Introducción a la Inteligencia Artificial
2. Visión General de un Sistema Inteligente
3. Optimización para modelos ML
4. Regresiones Lineal
5. Regresión Logística
6. Métricas de Desempeño y regularización

5. Metodología del aprendizaje:

Clases teórico, prácticas y trabajo de investigación independiente.

6. Sistema de evaluación del aprendizaje:

Pruebas de evaluación escritas y prácticas.

7. Actividades de investigación:

NO APLICA.

8. Actividades de extensión:

NO APLICA.

9. Referencias bibliográficas:

Básicas

1. James, Gareth, et al. An introduction to statistical learning. Vol. 112. New York: springer, 2013.
2. Géron, a. (2019). Hands-on machine learning with scikit-learn, keras, and tensorflow: concepts, tools, and techniques to build intelligent systems. O'reilly media.
3. François Chollet - Deep Learning with Python-Manning (2018).
4. Andrieu, C., N. de Freitas, A. Doucet, and M. I. Jor dan (2003). An introduction to MCMC for machine learning. Machine Learning 50, 5–43.
5. Anthony, M. and N. Biggs (1992). An Introduction to Computational Learning Theory. Cambridge University Press.
6. Bather, J. (2000). Decision Theory: An Introduction to Dynamic Programming and Sequential Decisions. Wiley.
7. Baudat, G. and F. Anouar (2000). Generalized discriminant analysis using a kernel approach. Neural Computation 12(10), 2385–2404.
8. Fletcher, R. (1987). Practical Methods of Optimization (Second ed.). Wiley.
9. Forsyth, D. A. and J. Ponce (2003). Computer Vision: A Modern Approach. Prentice Hall.
10. Freund, Y. and R. E. Schapire (1996). Experiments with a new boosting algorithm. In L. Saitta (Ed.), Thirteenth International Conference on Machine Learning, pp. 148–156. Morgan Kaufmann.

Complementarias

1. Jolliffe, I. T. (2002). Principal Component Analysis (Second ed.). Springer.
2. Jordan, M. I. (1999). Learning in Graphical Models. MIT Press.
3. Robbins, H. and S. Monro (1951). A stochastic approximation method. Annals of Mathematical Statistics 22, 400–407.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(63)

4. Robert, C. P. and G. Casella (1999). Monte Carlo Statistical Methods. Springer.
5. Shawe-Taylor, J. and N. Cristianini (2004). Kernel Methods for Pattern Analysis. Cambridge University Press.
6. Vapnik, V. N. (1982). Estimation of dependences based on empirical data. Springer.
7. Vapnik, V. N. (1995). The nature of statistical learning theory. Springer.
8. Vapnik, V. N. (1998). Statistical learning theory. Wiley.
9. Wiegerinck, W. and T. Heskes (2003). Fractional belief propagation. In S. Becker, S. Thrun, and K. Obermayer (Eds.), Advances in Neural Information Processing Systems, Volume 15, pp. 455–462. MIT Press.
10. Williams, C. K. I. (1998). Computation with infinite neural networks. Neural Computation 10(5), 1203–1216.
11. Poggio, T. and F. Girosi (1990). Networks for approximation and learning. Proceedings of the IEEE 78(9), 1481–1497.
12. Powell, M. J. D. (1987). Radial basis functions for multivariable interpolation: a review. In J. C. Mason and M. G. Cox (Eds.), Algorithms for Approximation, pp. 143–167. Oxford University Press.
13. Rasmussen, C. E. and C. K. I. Williams (2006). Gaussian Processes for Machine Learning. MIT Press.
14. Rauch, H. E., F. Tung, and C. T. Striebel (1965). Maximum likelihood estimates of linear dynamical systems. AIAA Journal 3, 1445–1450.
15. Quinlan, J. R. (1986). Induction of decision trees. Machine Learning 1(1), 81–106.



“Tradición y Excelencia en la formación de Ingenieros”

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(64)

Código	MSCIA06
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	SEGUNDO SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Introducción a la Redes Neuronales
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA05

1. **Fundamentación:**

En 1958 Rosenblatt elabora el modelo de red neuronal llamada perceptrón, dicho modelo estaba formado por una única neurona artificial que posee una salida binaria y que es capaz de variar sus pesos y resolver problemas lineales. Sin embargo, en la actualidad las redes neuronales son una de las técnicas con mayor número y variedad de aplicaciones a todos los campos de la ciencia, la ingeniería, la medicina, la arquitectura. A diario aparecen en los medios de comunicación noticias que relacionan a las redes neuronales con aplicaciones novedosas, sorprendentes y muy prometedoras.

2. **Objetivo General:**

- Introducir a los estudiantes las arquitecturas básicas de las redes neuronales, su entrenamiento y aplicación a problemas de clasificación y regresión.

3. **Objetivos Específicos:**

- Aplicar las redes neuronales a la resolución de problemas de regresión y clasificación.
- Identificar los diferentes algoritmos de optimización utilizados para el entrenamiento y el ajuste de hiperparámetros.

4. **Contenidos:**

1. Introducción a las Redes Neuronales
2. Arquitecturas básicas
3. Entrenamiento con propagación hacia atrás
4. Clasificación Binaria y Multiclase



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(65)

5. Regresión y redes recurrentes
6. Métodos de Optimización
7. Optimización de Hiper parámetros

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Charu C. Aggarwal . Neural Networks and Deep Learning, Springer 2018.
2. Christopher M. Bishop Neural Networks for Pattern Recognition.Oxford University Press, USA 2005
3. Géron, a. (2019). Hands-on machine learning with scikit-learn, keras, and tensorflow: concepts, tools, and techniques to build intelligent systems. O'reilly media.
4. Aaron Courville, Ian Goodfellow y Yoshua Bengio. Deep learning.
5. Ackley, D. H., Hinton, G. E., and Sejnowski, T. J. (1985). A learning algorithm for Boltzmann machines. Cognitive Science, 9, 147–169. 567, 651
6. Alain, G. and Bengio, Y. (2013). What regularized auto-encoders learn from the datagenerating distribution. In ICLR'2013, arXiv:1211.4246 . 504, 509, 512, 518
7. Alain, G., Bengio, Y., Yao, L., Éric Thibodeau-Laufer, Yosinski, J., and Vincent, P. (2015).GSNs: Generative stochastic networks. arXiv:1503.05571. 507, 709
8. Allen, R. B. (1987). Several studies on natural language and back-propagation. In IEEEFirst International Conference on Neural Networks, volume 2, pages 335–341, SanDiego. 468
9. Anderson, E. (1935). The Irises of the Gaspé Peninsula. Bulletin of the American Iris Society, 59, 2–5. 19
10. Ba, J., Mnih, V., and Kavukcuoglu, K. (2014). Multiple object recognition with visualattention. arXiv:1412.7755. 688.

Complementarias

1. Bachman, P. and Precup, D. (2015). Variational generative stochastic networks withcollaborative shaping. In Proceedings of the 32nd International Conference on MachineLearning, ICML 2015, Lille, France, 6-11 July 2015 , pages 1964–1972. 713.
2. Bacon, P.-L., Bengio, E., Pineau, J., and Precup, D. (2015). Conditional computation inneural networks using a decision-theoretic approach. In 2nd Multidisciplinary Conference on Reinforcement Learning and Decision Making (RLDM 2015). 445717.
3. Bagnell, J. A. and Bradley, D. M. (2009). Differentiable sparse coding. In D. Koller,D. Schuurmans, Y. Bengio, and L. Bottou, editors, Advances in Neural InformationProcessing Systems 21 (NIPS'08), pages 113–120. 494



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(66)

4. Bahdanau, D., Cho, K., and Bengio, Y. (2015). Neural machine translation by jointly learning to align and translate. In ICLR'2015, arXiv:1409.0473 . 25, 99, 392, 412, 415, 459, 470, 471
5. Bahl, L. R., Brown, P., de Souza, P. V., and Mercer, R. L. (1987). Speech recognition with continuous-parameter hidden Markov models. Computer, Speech and Language, 2, 219–234. 453
6. Baldi, P. and Hornik, K. (1989). Neural networks and principal component analysis: Learning from examples without local minima. Neural Networks, 2, 53–58. 283
7. Baldi, P., Brunak, S., Frasconi, P., Soda, G., and Pollastri, G. (1999). Exploiting the past and the future in protein secondary structure prediction. Bioinformatics, 15(11), 937–946. 388
8. Baldi, P., Sadowski, P., and Whiteson, D. (2014). Searching for exotic particles in high-energy physics with deep learning. Nature communications, 5. 26
9. Ballard, D. H., Hinton, G. E., and Sejnowski, T. J. (1983). Parallel vision computation. Nature. 447
10. Barlow, H. B. (1989). Unsupervised learning. Neural Computation, 1, 295–311. 144
11. Barron, A. E. (1993). Universal approximation bounds for superpositions of a sigmoidal function. IEEE Trans. on Information Theory, 39, 930–945. 195
12. Bartholomew, D. J. (1987). Latent variable models and factor analysis. Oxford University Press. 486
13. Basilevsky, A. (1994). Statistical Factor Analysis and Related Methods: Theory and Applications. Wiley. 486
14. Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I. J., Bergeron, A., Bouchard, N., and Bengio, Y. (2012).
15. Theano: new features and speed improvements. Deep Learning and Unsupervised Feature Learning NIPS 2012 Workshop. 25, 80, 210, 218, 441.



“Tradición y Excelencia en la formación de Ingenieros”

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(67)

Código	MSCIA07
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	SEGUNDO SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Aprendizaje Profundo
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA06

1. Fundamentación:

Los algoritmos de aprendizaje profundo se han convertido en una tendencia creciente para varias soluciones de software en campos como el procesamiento del lenguaje natural, visión por computador y la robótica, siendo núcleo de tecnologías de gran éxito como Alexa, Google Lens entre otros.

En la era del Big Data y de grandes avances en la tecnología del cómputo, estos algoritmos han encontrado el momento propicio para florecer y apuntalar nuevos hitos en el procesamiento de los datos, especialmente debido a su gran capacidad de representación de la información en distintos niveles, donde las características más representativas son extraídas directamente de los datos con mínima participación humana.

Para entender el funcionamiento de estos algoritmos es necesario comprender sus principios básicos, la estructura de representación de la información, las arquitecturas de las redes más resaltantes y las estrategias de entrenamiento para obtener el mejor resultado.

2. Objetivo General:

Identificar y aplicar modelos de aprendizaje profundo a diferentes tipos de datos (imagen, texto y audio) aplicados a distintas áreas de la ciencia (medicina, ingeniería, entre otros).



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(68)

3. Objetivos Específicos:

- Desarrollar capacidades de implementar algoritmos basados en aprendizaje de máquina para resolver problemas de las ciencias y la ingeniería de datos utilizando modelos basados en el aprendizaje profundo.
- Identificar las principales arquitecturas del estado del arte.
- Implementar los algoritmos en plataformas web y/o hardware.

4. Contenidos:

1. Redes Convolucionales
2. Redes Generativas Adversarias
3. Redes Recurrentes
4. Aprendizaje por refuerzo
5. Implementación en sistemas Web, Hardware o Celular

5. Metodología del aprendizaje:

Clases teórico, prácticas y trabajo de investigación independiente.

6. Sistema de evaluación del aprendizaje:

Pruebas de evaluación escritas y prácticas.

7. Actividades de investigación:

NO APLICA.

8. Actividades de extensión:

NO APLICA.

9. Referencias bibliográficas:

Básicas

1. Jeff Heaton. Artificial intelligence for humans, volume 3: deep learning and neural networks (9781505714340).
2. Aaron Courville, Ian Goodfellow y Yoshua Bengio. Deep learning.
3. Andrew W. Trask - Grokking Deep Learning-Manning (2019)
4. Vasilev, I., Slater, D., Spacagna, G., Roelants, P., & Zocca, V. (2019). Python Deep Learning: Exploring deep learning techniques and neural network architectures with Pytorch, Keras, and TensorFlow. Packt Publishing Ltd.
5. Torres, J. (2020). Python deep learning. Marcombo.
6. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
7. Bayer, J. and Osendorfer, C. (2014). Learning stochastic recurrent networks. ArXiv-prints. 262
8. Becker, S. and Hinton, G. (1992). A self-organizing neural network that discovers surfaces in random-dot stereograms. Nature, 355, 161–163. 539
9. Behnke, S. (2001). Learning iterative image reconstruction in the neural abstraction pyramid. Int. J. Computational Intelligence and Applications, 1(4), 427–438. 511
10. Beiu, V., Quintana, J. M., and Avedillo, M. J. (2003). VLSI implementations of threshold logic-a comprehensive survey. Neural Networks, IEEE Transactions on, 14(5), 1217–1243. 446.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(69)

Complementarias

1. Belkin, M. and Niyogi, P. (2002). Laplacian eigenmaps and spectral techniques for embedding and clustering. In T. Dietterich, S. Becker, and Z. Ghahramani, editors, Advances in Neural Information Processing Systems 14 (NIPS'01), Cambridge, MA. MIT Press. 240.
2. Belkin, M. and Niyogi, P. (2003). Laplacian eigenmaps for dimensionality reduction and data representation. Neural Computation, 15(6), 1373–1396. 160, 516.
3. Bengio, Y. and Bengio, S. (2000b). Modeling high-dimensional discrete data with multi-layer neural networks. In NIPS 12, pages 400–406. MIT Press.
4. Bengio, Y. and Delalleau, O. (2009). Justifying and generalizing contrastive divergence. Neural Computation, 21(6), 1601–1621. 509, 609.
5. Bengio, Y. and Grandvalet, Y. (2004). No unbiased estimator of the variance of k-fold cross-validation. In S. Thrun, L. Saul, and B. Schölkopf, editors, Advances in Neural Information Processing Systems 16 (NIPS'03), Cambridge, MA. MIT Press, Cambridge. 120
6. Bengio, Y. and LeCun, Y. (2007). Scaling learning algorithms towards AI. In Large Scale Kernel Machines. 18
7. Bengio, Y. and Monperrus, M. (2005). Non-local manifold tangent learning. In L. Saul, Y. Weiss, and L. Bottou, editors, Advances in Neural Information Processing Systems 17 (NIPS'04), pages 129–136. MIT Press. 157, 518
8. Bengio, Y. and Sénécal, J.-S. (2003). Quick training of probabilistic neural nets by importance sampling. In Proceedings of AISTATS 2003. 465
9. Bengio, Y. and Sénécal, J.-S. (2008). Adaptive importance sampling to accelerate training of a neural probabilistic language model. IEEE Trans. Neural Networks, 19(4), 713–722. 465
10. Bengio, Y., De Mori, R., Flammia, G., and Kompe, R. (1991). Phonetically motivated acoustic parameters for continuous speech recognition using artificial neural networks. In Proceedings of EuroSpeech'91. 23, 454
11. Bengio, Y., De Mori, R., Flammia, G., and Kompe, R. (1992). Neural network-Gaussian mixture hybrid for speech recognition or density estimation. In NIPS 4, pages 175–182. Morgan Kaufmann. 454
12. Bengio, Y., Frasconi, P., and Simard, P. (1993). The problem of learning long-term dependencies in recurrent networks. In IEEE International Conference on Neural Networks, pages 1183–1195, San Francisco. IEEE Press. (invited paper). 398
13. Bengio, Y., Simard, P., and Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. IEEE Tr. Neural Nets. 17, 396, 398, 399, 407
14. Bengio, Y., Latendresse, S., and Dugas, C. (1999). Gradient-based learning of hyper-parameters. Learning Conference, Snowbird. 430
15. Bengio, Y., Ducharme, R., and Vincent, P. (2001). A neural probabilistic language model. In T. K. Leen, T. G. Dietterich, and V. Tresp, editors, NIPS'2000, pages 932–938. MIT Press. 17, 442, 458, 461, 467, 472, 477



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(70)

15. Bengio, Y., Ducharme, R., Vincent, P., and Jauvin, C. (2003). A neural probabilistic language model. JMLR, 3, 1137–1155. 461, 467720



"Tradición y Excelencia en la formación de Ingenieros"

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA08
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	SEGUNDO SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Metodología y gestión de proyectos de investigación
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA04



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(71)

1. **Fundamentación:**

La Metodología de la Investigación Científica es la ciencia que aporta un conjunto de métodos, categorías, leyes y procedimientos que garantizan la solución de los problemas científicos con un máximo de eficiencia. El problema científico, se concreta a través de preguntas e hipótesis, donde las preguntas son expresión de lo desconocido, mientras que las hipótesis son afirmaciones o conjeturas que se hacen para contestar dichas preguntas. Estas deben poseer atributos que posibiliten abordarlas en un trabajo de investigación. De ellos los fundamentales son la especificidad, que sean empíricamente contrastables y la fundamentación científica. De la especificidad con que se hayan declarado las hipótesis y preguntas depende en gran medida el éxito de la investigación. Si una investigación es un intento concreto de resolver cierto problema científico, entonces la misma debe estar en función de una pregunta/hipótesis lo suficientemente específica como para permitir abordarla.

2. **Objetivo General:**

Identificar las principales metodologías para plantear, implementar y gestionar de proyectos de investigación.

3. **Objetivos Específicos:**

- Desarrollar los conceptos básicos para el desarrollo de una investigación.
- Explicar los métodos y la visión del investigador para la resolución de problemas reales.
- Implementar soluciones enfocadas a la industria y a la resolución de problemas nacionales.
- Modelar y plantear una investigación, así como un proyecto de investigación.

4. **Contenidos:**

1. Ciencia, tecnología e investigación.
2. El investigador. Métodos de Investigación.
3. Investigación en la Industria.
4. Creatividad en la investigación.
5. Difusión y comunicación de la investigación.
6. Proyectos de investigación.

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

8. **Referencias bibliográficas:**

Básicas

1. Hernández-Sampieri, R., & Torres, C. P. M. (2018). Metodología de la investigación (Vol. 4, pp. 310-386). México: McGraw-Hill Interamericana.
2. Sánchez, J. C. (2004). Metodología de la investigación científica y tecnológica. Ediciones Díaz de Santos.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(72)

3. Project Management Institute. (2017). Guía de los Fundamentos para la Dirección de Proyectos Guía del PMBOK. Project Management Institute.
4. Martín Mayorga D. La Ciencia en tus manos. La sociedad de la información, págs. 615-634. Edit. Espasa Calpe, S. A., Madrid, 2001.
6. Fernández Durán R. La ciencia en tus manos. Los transportes, págs. 707-744. Edit. Espasa Calpe, S. A., Madrid, 2001.
7. Alario Miguel Á. La ciencia en tus Manos. Los materiales, págs. 746-780. Edit. Espasa Calpe, S. A., Madrid, 2001.
8. Fernández-Galiano L. y Paricio I. La ciencia en tus manos. La Arquitectura y su Construcción, págs. 781-807. Edit. Espasa Calpe, S. A., Madrid, 2001.
9. Asthon W. B., Klavans R. A. Keeping Abreast of Science and Technology. Technical Intelligence for Business, Batelle Press, Columbus, USA, 1997.
10. Escorsa P., Valls J. Tecnología e innovación en la empresa. Dirección y gestión, pág. 74. Edit. UPC, Barcelona, 1997.

Complementarias

1. Palop F., Vicente J.M. Estructura de la vigilancia. Master en Gestión de la Ciencia y la Tecnología, Universidad de Carlos III, Madrid, 1994.
2. Amat N. La documentación y sus tecnologías. Edit. Pirámide, Madrid, 1994.
3. Sancho R. Indicadores bibliométricos utilizados en la Ciencia y en la Tecnología. Revisión bibliográfica, Revista Española de Documentación Científica n.º 13, 1990.
4. Escorsa P., Maspons R., Rodríguez M. Mapas tecnológicos, estrategia empresarial y oportunidades de mercado. El caso de los textiles para usos médicos. Boletín Intexter n.º 117, pág. 57, UPC, 2000.
5. Cetron M.V. Technological Forecasting. A Practical Approach. Edit. Gordon & Breach, 1969.
6. Fermin de la Sierra, Estrategia de la innovación tecnológica, pág. 216. Edit. ETS. Ingenieros Industriales de Madrid, 1981.
7. Cámara Oficial de Comercio, Industria y Navegación de Barcelona, Investigación e innovación tecnológica en la industria, pág. 32, Barcelona, 1971.
8. Marquis D.G. The Anatomy of Successful Innovations, National Science Foundation, págs. 29-37, 1977.
9. De la Sierra F. Estrategia de la innovación tecnológica, Edit. Sección de Publicaciones de la ETS Ingenieros Industriales, Madrid, 1981.
10. Lowe J. y Crawford N. Innovation and Technology transfer for the growing firm, Edit. Pergamon Press, Oxford, 1984.
11. Suris J.M. La empresa industrial española ante la Innovación Tecnológica, Edit. Hispano Europea, Barcelona, 1986.
12. Twiss B. Managing Technological Innovation. Edit. Pitman Publishing Limited, London, 1986.
13. Ruiz Gonzalez M. y Mandado Pérez E. La innovación tecnológica y su gestión, Edit. Marcombo S. A., Barcelona, 1989.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(73)

14. Escorsa Castell P. Valls Pasola J Tecnología e Innovación en la empresa, Dirección y Gestión, Edicions UPC, Barcelona 1997.
15. Baker N.R. Siegman J. A.H. Rubenstein, IEEE Trans. Eng. Manage. Edit. E-M, December 1967.



"Tradición u Excelencia en la formación de Ingenieros"

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA09
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	TERCER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Sistemas de Recomendación
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA05



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(74)

1. **Fundamentación:**

Muchos sistemas de e-commerce hoy en día funcionan a través de sistemas de recomendación. Para poder desarrollar e implementar dichos sistemas es indispensable conocer los modelos matemáticos que se emplean.

2. **Objetivo General:**

Introducir a los alumnos los sistemas de recomendación, su historia, modelos matemáticos, algoritmos, el problema de la escasez de datos, latent factor models, etc.

3. **Objetivos Específicos:**

- Identificar los problemas que pueden ser planteados como sistemas de recomendación.
- Entender los fundamentos matemáticos que sustentan los algoritmos del estado del arte.
- Tratar adecuadamente el problema de la escasez de datos.

4. **Contenidos:**

1. Introducción a los sistemas de Recomendación
2. Neighborhood-based collaborative filtering
3. Model-based collaborative filtering
4. Content-based recommender systems
5. Evaluación de sistemas de recomendación

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Aggarwal, Charu C. Recommender systems. Vol. 1. Cham: Springer International Publishing, 2016.
2. Lü, Linyuan, et al. "Recommender systems." Physics reports 519.1 (2012): 1-49.
3. Koren, Yehuda, Robert Bell, and Chris Volinsky. "Matrix factorization techniques for recommender systems." Computer 42.8 (2009): 30-37.
4. Luo, Xin, et al. "An efficient non-negative matrix-factorization-based approach to collaborative filtering for recommender systems." IEEE Transactions on Industrial Informatics 10.2 (2014): 1273-1284.
5. Ning, Xia, and George Karypis. "Slim: Sparse linear methods for top-n recommender systems." 2011 IEEE 11th international conference on data mining. IEEE, 2011.
6. H. Steck. Evaluation of recommendations: rating-prediction and ranking. ACM Conference on Recommender Systems, pp. 213–220, 2013.
7. H. Stormer. Improving e-commerce recommender systems by the identification of seasonal products. Conference on Artificial Intelligence, pp. 92–99, 2007.
8. G. Strang. An introduction to linear algebra. Wellesley Cambridge Press, 2009.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(75)

9. N. Srebro, J. Rennie, and T. Jaakkola. Maximum-margin matrix factorization. *Advances in neural information processing systems*, pp. 1329–1336, 2004.
10. Su and T. Khoshgoftaar. A survey of collaborative filtering techniques. *Advances in artificial intelligence*, 4, 2009.

Complementarias

11. X. Su, T. Khoshgoftaar, X. Zhu, and R. Greiner. Imputation-boosted collaborative filtering using machine learning classifiers. *ACM symposium on Applied computing*, pp. 949–950, 2008.
12. X. Su, H. Zeng, and Z. Chen. Finding group shilling in recommendation system. *World Wide Web Conference*, pp. 960–961, 2005.
13. K. Subbian, C. Aggarwal, and J. Srivasatava. Content-centric flow mining for influence analysis in social streams. *CIKM Conference*, pp. 841–846, 2013.
14. B. O'Sullivan, A. Papadopoulos, B. Faltings, and P. Pu. Representative explanations for over-constrained problems. *AAAI Conference*, pp. 323–328, 2007.
15. J. Sun and J. Tang. A survey of models and algorithms for social influence analysis. *Social Network Data Analytics*, Springer, pp. 177–214, 2011.
16. Y. Sun, J. Han, C. Aggarwal, and N. Chawla. When will it happen?: relationship prediction in heterogeneous information networks. *ACM International Conference on Web Search and Data Mining*, pp. 663–672, 2012.
17. Y. Sun, R. Barber, M. Gupta, C. Aggarwal, and J. Han. Co-author relationship prediction in heterogeneous bibliographic networks. *Advances in Social Networks Analysis and Mining (ASONAM)*, pp. 121–128, 2011.
18. D. Sutherland, B. Póczos, and J. Schneider. Active learning and search on low-rank matrices. *ACM KDD Conference*, pp. 212–220, 2013.
19. P. Symeonidis, A. Nanopoulos, and Y. Manolopoulos. Tag recommendations based on tensor dimensionality reduction. *ACM Conference on Recommender Systems*, pp. 43–50, 2008.
20. M. Szomszor, C. Cattuto, H. Alani, K. O'Hara, A. Baldassarri, V. Loreto, and V. Servedio. Folksonomies, the semantic web, and movie recommendation. *Bridging the Gap between the Semantic Web and Web 2.0*, pp. 71–84, 2007.
21. N. Taghipour, A. Kardan, and S. Ghidary. Usage-based web recommendations: a reinforcement learning approach. *ACM Conference on Recommender Systems*, pp. 113–120, 2007.
22. G. Takacs, I. Pilaszy, B. Nemeth, and D. Tikk. Matrix factorization and neighbor based algorithms for the Netflix prize problem. *ACM Conference on Recommender Systems*, pp. 267–274, 2008.
23. G. Takacs, I. Pilaszy, B. Nemeth, and D. Tikk. Scalable collaborative filtering approaches for large recommender systems. *Journal of Machine Learning Research*, 10, pp. 623–656, 2009.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(76)

24. J. Tang, X. Hu, and H. Liu. Social recommendation: a review. Social Network Analysis and Mining, 3(4), pp. 1113–1133, 2013.
25. J. Tang, J. Sun, C. Wang, and Z. Yang. Social influence analysis in large-scale networks. ACM KDD Conference, pp. 807–816, 2009.



“Tradición y Excelencia en la formación de Ingenieros”

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA10
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	TERCER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Series Temporales
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA06



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(77)

1. Fundamentación:

Los casos de uso de pronóstico de series de tiempo son sin duda los casos de uso de series de tiempo más comunes, ya que se pueden encontrar en todo tipo de industrias y en varios contextos. Ya sea pronosticando las ventas futuras para optimizar el inventario, prediciendo el consumo de energía para adaptar los niveles de producción o estimando el número de pasajeros de las aerolíneas para garantizar servicios de alta calidad, el tiempo es una variable clave. Sin embargo, lidiar con series de tiempo puede ser un desafío. Los datos, que consisten en secuencias de observaciones registradas a intervalos de tiempo regulares, pueden contener ruido, ser muy desiguales o incluso ser intermitentes según el contexto.

Los enfoques tradicionales pueden ser demasiado simplistas y tienden a requerir pasos de procesamiento previo y posterior que consumen mucho tiempo para garantizar resultados de rendimiento satisfactorios. En las últimas décadas, los modelos de aprendizaje profundo han tenido un gran éxito. Su aplicación para casos de uso relacionados con el procesamiento del lenguaje natural (NLP), la clasificación de imágenes o el modelado de audio ha superado constantemente los enfoques tradicionales y ha alterado los hábitos comerciales. En cuanto a la previsión de series temporales, muchos trabajos de investigación han aplicado con éxito métodos de aprendizaje profundo. Han propuesto modelos que pueden no solo superar los problemas encontrados con los enfoques estadísticos, sino también manejar mejor la complejidad del pronóstico de series de tiempo y, por lo tanto, obtener resultados significativamente mejorados.

2. Objetivo General:

Conocer los modelos del estado del arte para la predicción, clasificación y detección de anomalías de series temporales

3. Objetivos Específicos:

- Identificar los principales modelos estadísticos utilizados para predecir series temporales.
- Conocer los modelos de aprendizaje profundo aplicables a series temporales.
- Implementar los modelos para resolver problemas de predicción y clasificación de series temporales.

4. Contenidos:

1. Introducción a las series temporales
2. Modelos estadísticos para predicción
3. Categorización de series temporales
4. Modelos de aprendizaje de máquina tradicionales aplicados a series temporales
5. Predicción y clasificación de series temporales a gran escala con aprendizaje profundo



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(78)

5. **Metodología del aprendizaje:**

Clases teórico, prácticas y trabajo de investigación independiente.

6. **Sistema de evaluación del aprendizaje:**

Pruebas de evaluación escritas y prácticas.

7. **Actividades de investigación:**

NO APLICA.

8. **Actividades de extensión:**

NO APLICA.

9. **Referencias bibliográficas:**

Básicas

1. Lazzeri, F. (2020). Machine learning for time series forecasting with Python. John Wiley & Sons.
2. Auffarth, B. (2021). Machine Learning for Time-Series with Python: Forecast, Predict, and Detect Anomalies with State-of-the-Art Machine Learning Methods.
3. Peixeiro, M. (2022). Time Series Forecasting in Python. Manning.
4. Gridin, I. (2021). Time Series Forecasting using Deep Learning: Combining PyTorch, RNN, TCN, and Deep Neural Network Models to Provide Production-Ready Prediction Solutions (English Edition). BPB Publications.
5. Shumway, R. H., & Stoffer, D. S. (2017). Time series analysis and its applications : with R examples. Springer.
6. Lara-Benítez, P., Carranza-García, M., & Riquelme, J. C. (2021). An experimental review on deep learning architectures for time series forecasting. International Journal of Neural Systems, 31(03), 2130001.
7. Bianchi, Filippo Maria, and Enrico Maiorino, Michael Kampffmeyer, Antonello Rizzi, Robert Jenssen. 2018. Recurrent Neural Networks for Short-Term Load Forecasting. Berlin, Germany: Springer.
8. Brownlee, Jason. 2017. Introduction to Time Series Forecasting With Python - Discover How to Prepare Data and Develop Models to Predict the Future. Machine Learning Mastery. <https://machinelearningmastery.com/introduction-to-time-series-forecasting-with-python/>.
9. Che, Zhengping, and Sanjay Purushotham, Kyunghyun Cho, David Sontag, Yan Liu. 2018. "Recurrent Neural Networks for Multivariate Time Series with Missing Values." Scientific Reports 8. <https://doi.org/10.1038/s41598-018-24271-9>.
10. Cheng H., Tan PN., Gao J., Scripps J. 2006. "Multistep-Ahead Time Series Prediction." In: Ng WK., Kitsuregawa M., Li J., Chang K. (eds) Advances in Knowledge Discovery and Data Mining, PAKDD 2006. Lecture Notes in Computer Science 3918. Berlin, Heidelberg: Springer. https://doi.org/10.1007/11731139_89.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

..//..(79)

Complementarias

1. Cho, Kyunghyun, and Bart van Merriënboer, Caglar Gulcehre, Fethi Bougares, Holger Schwenk, Y Bengio. 2014. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. <https://doi.org/10.3115/v1/D14-1179>.
2. Glen, Stephanie. 2014. "Endogenous Variable and Exogenous Variable: Definition and Classifying." Statistics How To blog. <https://www.statisticshowto.com/endogenous-variable/>.
3. Lazzeri, Francesca. 2019a. "3 reasons to add deep learning to your time series toolkit." O'Reilly Ideas blog. <https://www.oreilly.com/content/3-reasons-to-add-deep-learning-to-your-time-series-toolkit/>.
4. Lazzeri, Francesca. 2019b. "Data Science Mindset: Six Principles to Build Healthy Data-Driven Organizations." InfoQ blog. <https://www.infoq.com/articles/data-science-organization-framework>.
5. Lazzeri, Francesca. 2019c. "How to deploy machine learning models with Azure Machine Learning." Educative.io blog. <https://www.educative.io/blog/how-to-deploy-your-machine-learning-model>.
6. Lewis-Beck, Michael S., and Alan Bryman, Tim Futing Liao. 2004. The Sage Encyclopedia of Social Science Research Methods. Thousand Oaks, Calif: Sage.
7. Nguyen, Giang, and Stefan Dlugolinsky, Martin Bobak, Viet Tran, Alvaro Lopez Garcia, Ignacio Heredia, Peter Malík, Ladislav Hluchý. 2019. "Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey". Artificial Intelligence Review 52: 77–124. <https://doi.org/10.1007/s10462-018-09679-z>.
8. Petris, G., and S. Petrone, P. Campagnoli. 2009. Dynamic Linear Models in R. Springer.
9. Poznyak, T., and J.I.C. Oria, A. Poznyak. 2018. Ozonation and Biodegradation in Environmental Engineering: Dynamic Neural Network Approach. Elsevier Science.
10. Stellwagen, Eric. 2011. "Forecasting 101: A Guide to Forecast Error Measurement Statistics and How to Use Them." ForecastPRO blog. <https://www.forecastpro.com/Trends/forecasting101August2011.html>.
11. Hong, Tao, and Pierre Pinson, Fan Shu, Hamidreza Zareipour, Alberto Troccoli, Rob J. Hyndman. 2016. "Probabilistic Energy Forecasting: Global Energy Forecasting Competition 2014 and Beyond." International Journal of Forecasting 32, no. 3 (July-September): 896–913.
12. Taylor, Christine. 2018. "Structured vs. Unstructured Data." Datamation blog. <https://www.datamation.com/big-data/structured-vs-unstructured-data.html>.
13. White, Halbert. 1980. "A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity." Econometrica, Econometric Society 48, no.4 (May):817–838.
14. Zhang, Ruiyang, and Zhao Chen, Chen Su, Jingwei Zheng, Oral Büyüköztürk, Hao Sun. 2019. "Deep long short-term memory networks for nonlinear structural seismic response prediction." Computers & Structures 220: 55–68. <https://doi.org/10.1016/j.compstruc.2019.05.006>.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

.../(80)

15. Zhang Y, and YT Zhang, JY Wang, XW Zheng. 2015. "Comparison of classification methods on EEG signals based on wavelet packet decomposition." Neural Comput Appl 26, no. 5:1217–1225.



"Tradición y Excelencia en la formación de Ingenieros"

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA11
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	TERCER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	Algoritmos para Aprendizaje No Supervisado
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA05



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../..(81)

1. Fundamentación:

El aprendizaje no supervisado es un conjunto de técnicas algorítmicas que toman datos sin categorizar y los clasifica en agrupamientos a través del descubrimiento de patrones en los mismos datos sin ninguna intervención externa al algoritmo.

Las capacidades de estos algoritmos para descubrir similitudes y diferencias en la información los hace aptos para el análisis de datos exploratorios, segmentación y categorización de datos, reconocimiento en imágenes, por nombrar algunas aplicaciones.

En este curso se presentarán los algoritmos clásicos para aprendizaje no supervisado consistentes en clustering y el análisis de componentes principales (o por sus siglas en inglés PCA). Luego se introducirán técnicas que apuntan a aumentar la eficiencia de los algoritmos de conglomerados y PCA a través de la reducción de la cantidad de datos. En general estas técnicas se conocen como técnicas de dispersión de datos, del inglés *sparse techniques*. Este curso hará énfasis en tres técnicas de dispersión de datos, la dispersión espectral de grafos y matrices, *sketching* y *compressed sensing*. Luego se mostrará como estas técnicas se aplican a clustering y PCA de manera a mejorar los tiempos de cómputos con una poca afectación en la calidad de las soluciones.

2. Objetivo General:

Proporcionar fundamentos sobre técnicas avanzadas de aprendizaje no supervisado.

3. Objetivos Específicos:

- Comprender el funcionamiento de clustering como un algoritmo de aproximación.
- Comprender los fundamentos matemáticos del análisis de componentes principales.
- Comprender los algoritmos de dispersión espectral de grafos y su aplicación a clustering y PCA.
- Aplicar técnicas básicas de *sketching* en el análisis de datos.
- Introducir la técnica de *compressed sensing* y su aplicación en el análisis de datos.

4. Contenidos:

1. Clustering.
2. Principal Component Analysis.
3. Spectral Sparsification.
4. Sketching.
5. Compressed sensing.

5. Metodología del aprendizaje:

Clases teórico, prácticas y trabajo de investigación independiente.

6. Sistema de evaluación del aprendizaje:

Pruebas de evaluación escritas y prácticas.

7. Actividades de investigación:

NO APLICA.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

../(82)

8. Actividades de extensión:

NO APLICA.

9. Referencias bibliográficas:

Básicas

1. Woodruff, D. P. (2014). Sketching as a tool for numerical linear algebra. Foundations and Trends® in Theoretical Computer Science, 10(1–2), 1-157.
2. Spielman, D. (2019). Spectral and Algebraic Graph Theory. <http://cs-www.cs.yale.edu/homes/spielman/sagt/>
3. Bhatia, R. (2013). Matrix analysis (Vol. 169). Springer Science & Business Media.
4. Von Luxburg, U. (2007). A tutorial on spectral clustering. Statistics and computing, 17(4), 395-416.
5. Jolliffe, I. T. (2002). Principal component analysis for special types of data (pp. 338-372). Springer New York.
6. Mendoza-Granada, F., & Villagra, M. (2021). A Distributed Algorithm for Spectral Sparsification of Graphs with Applications to Data Clustering. In Graphs and Combinatorial Optimization: from Theory to Applications (pp. 403-413). Springer, Cham.
7. Mercado, S., & Villagra, M. (2022). Bounds on the spectral sparsification of symmetric and off-diagonal nonnegative real matrices. Discrete Mathematics, Algorithms and Applications, 14(02), 2150109.
8. Spielman, D. A., & Srivastava, N. (2008, May). Graph sparsification by effective resistances. In Proceedings of the fortieth annual ACM symposium on Theory of computing (pp. 563-568).
9. Wickman, R., Zhang, X., & Li, W. (2021). Sparrl: Graph sparsification via deep reinforcement learning. arXiv preprint arXiv:2112.01565.
10. Batson, J., Spielman, D. A., Srivastava, N., & Teng, S. H. (2013). Spectral sparsification of graphs: theory and algorithms. Communications of the ACM, 56(8), 87-94.

Complementarias

1. Goranci, G. (2019). Dynamic graph algorithms and graph sparsification: New techniques and connections. arXiv preprint arXiv:1909.06413.
2. Czumaj, A., Davies, P., & Parter, M. (2021). Graph sparsification for derandomizing massively parallel computation with low space. ACM Transactions on Algorithms (TALG), 17(2), 1-27.
3. Yu, S., Alesiani, F., Yin, W., Jenssen, R., & Principe, J. C. (2022). Principle of Relevant Information for Graph Sparsification. arXiv preprint arXiv:2206.00118.
4. Chen, Y., Khanna, S., & Li, H. (2022). On weighted graph sparsification by linear sketching. arXiv preprint arXiv:2209.07729.
5. Zhao, Z., & Feng, Z. (2020). A Unified Spectral Sparsification Framework for Directed Graphs.
6. Wickman, R., Zhang, X., & Li, W. (2021). Sparrl: Graph sparsification via deep reinforcement learning. arXiv preprint arXiv:2112.01565.
7. Laeuchli, J. (2020, May). Fast community detection with graph sparsification. In Pacific-Asia Conference on Knowledge Discovery and Data Mining (pp. 291-304). Springer, Cham.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(83)

8. Batjargal, D., Khan, K. U., & Lee, Y. K. (2019). EM-FGS: Graph sparsification via faster semi-metric edges pruning. *Applied Intelligence*, 49(10), 3731-3748.
9. Feng, Z. (2020). Grass: Graph spectral sparsification leveraging scalable spectral perturbation analysis. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 39(12), 4944-4957.
10. Li, J., Zhang, T., Tian, H., Jin, S., Fardad, M., & Zafarani, R. (2020, May). SgcN: A graph sparsifier based on graph convolutional networks. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining* (pp. 275-287). Springer, Cham.
11. Lai, M. J., Xie, J., & Xu, Z. (2020). Graph sparsification by universal greedy algorithms. *arXiv preprint arXiv:2007.07161*.
12. Fung, W. S., Hariharan, R., Harvey, N. J., & Panigrahi, D. (2011, June). A general framework for graph sparsification. In *Proceedings of the forty-third annual ACM symposium on Theory of computing* (pp. 71-80).
13. Li, J., Zhang, T., Tian, H., Jin, S., Fardad, M., & Zafarani, R. (2022). Graph sparsification with graph convolutional networks. *International Journal of Data Science and Analytics*, 13(1), 33-46.
14. Mazuran, M., Tipaldi, G. D., Spinello, L., & Burgard, W. (2014, July). Nonlinear Graph Sparsification for SLAM. In *Robotics: Science and Systems* (pp. 1-8).
15. Spielman, D. A., & Teng, S. H. (2011). Spectral sparsification of graphs. *SIAM Journal on Computing*, 40(4), 981-1025.



"Tradición y Evolución en la formación de Ingenieros"

SEDE, CAMPUS DE LA UNA, SAN LORENZO

FACULTAD DE INGENIERÍA

DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA

PROGRAMA DE ACTIVIDADES ACADÉMICAS

MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(84)

Código	MSCIA12
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	TERCER SEMESTRE
Área	DOCENCIA
Nombre de la actividad académica	AI aplicada a Robótica
Carga horaria semanal	36
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA07

1. Fundamentación:

Los Vehículos Autónomos (VA) son aquellos que operan con mínima intervención humana para tareas de monitorización de procesos y exploración de entornos. Esto gracias a la reducción de costos de componentes electrónicos y de procesamiento computacional. Para alcanzar sus objetivos deben contar con un sistema de Guía, Navegación y Control (GNC) para determinar el camino a seguir, caracterizar el entorno en el que se encuentra y actuar sobre los propulsores de movimiento. Diferentes técnicas de Inteligencia Artificial pueden ser utilizadas para resolver los desafíos presentes en cada una de estas tareas, como, por ejemplo, la planificación de rutas y la percepción del entorno mediante visión artificial.

2. Objetivo General:

Proveer a los alumnos los fundamentos de los principales desafíos que se encuentran actualmente en la robótica, con énfasis en los VA, y cuáles son las técnicas de Inteligencia Artificial que se utilizan para resolver dichos problemas. Específicamente involucra a los sistemas de GNC.

3. Objetivos Específicos:

- Identificar los fundamentos necesarios para modelar los vehículos autónomos.
- Conocer los principales algoritmos de planificación y navegación de los VA.
- Implementar sistemas de control en VA.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(85)

4. Contenidos:

1. Introducción a la Robótica
2. Fundamentos de Vehículos Autónomos (VA)
3. Modelado de VA
4. Planificación de VA
5. Navegación de VA
6. Control de VA

5. Metodología del aprendizaje:

Clases teórico, prácticas y trabajo de investigación independiente.

6. Sistema de evaluación del aprendizaje:

Pruebas de evaluación escritas y prácticas.

7. Actividades de investigación:

NO APLICA.

8. Actividades de extensión:

NO APLICA.

9. Referencias bibliográficas:

Básicas

1. Correll, N. (2016). Introduction to Autonomous Robots: Kinematics, Perception, Localization and Planning (2nd ed.). Magellan Scientific.
2. Thrun, S., Burgard, W., & Fox, D. (2005). Probabilistic Robotics (Intelligent Robotics and Autonomous Agents series) (1st ed.). The MIT Press.
3. Corke, P. I., & Khatib, O. (2011). Robotics, vision and control: fundamental algorithms in MATLAB (Vol. 73, p. 2). Berlin: Springer.
4. LaValle, S. M. (2006). Planning algorithms. Cambridge university press.
5. Choset, H., Lynch, K. M., Hutchinson, S., Kantor, G. A., & Burgard, W. (2005). Principles of robot motion: theory, algorithms, and implementations. MIT press.
6. Wahde, M. (2012). Introduction to autonomous robots. Lecture Notes from the course Autonomous Agents, Chalmers university of technology.
7. Siciliano, B., Khatib, O., & Kröger, T. (Eds.). (2016). Springer handbook of robotics. Springer cham
8. Joseph, L. (2018). Robot operating system (ros) for absolute beginners. Springer.
9. Quan, Q., Dai, X., & Wang, S. (2020). Multicopter Design and Control Practice: A Series Experiments Based on MATLAB and Pixhawk. Springer Nature.
10. Sakai, A., Ingram, D., Dinius, J., Chawla, K., Raffin, A., & Paques, A. (2018). Pythonrobotics: a python code collection of robotics algorithms. arXiv preprint arXiv:1808.10703.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)

Resolución N° 0057-00-2023

./../(86)

Complementarias

1. Labbe Jr, R. R. (2022). Kalman and Bayesian Filters in Python. <https://github.com/rlabbe/Kalman-and-Bayesian-Filters-in-Python>
2. Joseph, L., & Cacace, J. (2018). Mastering ROS for Robotics Programming: Design, build, and simulate complex robots using the Robot Operating System. Packt Publishing Ltd.
3. Cass, S. (2020). Nvidia makes it easy to embed AI: The Jetson nano packs a lot of machine-learning power into DIY projects-[Hands on]. IEEE Spectrum, 57(7), 14-16.
4. Süzen, A. A., Duman, B., & Şen, B. (2020, June). Benchmark analysis of jetson tx2, jetson nano and raspberry pi using deep-cnn. In 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA) (pp. 1-5). IEEE.
5. Nowak, M. M., Dziób, K., & Bogawski, P. (2018). Unmanned Aerial Vehicles (UAVs) in environmental biology: A review. European Journal of Ecology, 4(2), 56-74.
6. Liu, Y., Dai, H. N., Wang, Q., Shukla, M. K., & Imran, M. (2020). Unmanned aerial vehicle for internet of everything: Opportunities and challenges. Computer communications, 155, 66-83.
7. Yao, H., Qin, R., & Chen, X. (2019). Unmanned aerial vehicle for remote sensing applications—A review. Remote Sensing, 11(12), 1443.
8. Rahman, M. F. F., Fan, S., Zhang, Y., & Chen, L. (2021). A comparative study on application of unmanned aerial vehicle systems in agriculture. Agriculture, 11(1), 22.
9. Peng, Z., Wang, J., Wang, D., & Han, Q. L. (2020). An overview of recent advances in coordinated control of multiple autonomous surface vehicles. IEEE Transactions on Industrial Informatics, 17(2), 732-745.
10. Vagale, A., Oucheikh, R., Bye, R. T., Osen, O. L., & Fossen, T. I. (2021). Path planning and collision avoidance for autonomous surface vehicles I: a review. Journal of Marine Science and Technology, 1-15.
11. Jorge, V. A., Granada, R., Maidana, R. G., Jurak, D. A., Heck, G., Negreiros, A. P., ... & Amory, A. M. (2019). A survey on unmanned surface vehicles for disaster robotics: Main challenges and directions. Sensors, 19(3), 702.
12. Bonadies, S., & Gadsden, S. A. (2019). An overview of autonomous crop row navigation strategies for unmanned ground vehicles. Engineering in Agriculture, Environment and Food, 12(1), 24-31.
13. Moud, H. I., Shojaei, A., & Flood, I. (2018, April). Current and future applications of unmanned surface, underwater, and ground vehicles in construction. In Proceedings of the Construction Research Congress (pp. 106-115).
14. Guastella, D. C., & Muscato, G. (2020). Learning-based methods of perception and navigation for ground vehicles in unstructured environments: A review. Sensors, 21(1), 73.
15. Balestrieri, E., Daponte, P., De Vito, L., & Lamonaca, F. (2021). Sensors and measurements for unmanned systems: An overview. Sensors, 21(4), 1518.



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(87)



“Tradición y excelencia en la formación de Ingenieros”
SEDE, CAMPUS DE LA UNA, SAN LORENZO
FACULTAD DE INGENIERÍA
DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA
PROGRAMA DE ACTIVIDADES ACADÉMICAS
MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA13
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	CUARTO SEMESTRE
Área	INVESTIGACION
Nombre de la actividad académica	Investigación Orientada para la Tesis de Maestría
Carga horaria semanal	No Aplica
Carga horaria total	180
Créditos académicos	6
Prerrequisitos	MSCIA09 MSCIA10 MSCIA11 MSCIA12



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

..//..(88)

1. **Fundamentación:**

La presentación de la Tesis es requisito obligatorio para la obtención del Título de Maestría, esta actividad consiste en la investigación realizada por el estudiante bajo la tutoría de un equipo de orientadores académicos.

2. **Objetivo General:**

Elaborar la tesis de maestría mediante el desarrollo y/o aplicación de técnicas de Inteligencia Artificial a un problema de las ciencias y/o la ingeniería.

3. **Contenidos:**

El contenido será definido en anteproyecto de investigación que debe ser presentado durante el desarrollo del módulo MSCIA08.

4. **Metodología de trabajo:**

Se realizan reuniones semanales para el control de avance de la investigación y la elaboración de artículos científicos. Los resultados de las investigaciones realizadas son presentados en congresos regionales y/o internacionales arbitrados por pares.

5. **Actividades de evaluación:**

El libro de tesis y la presentación final de la tesis se evalúan con siguiente ponderación:

Texto de la tesis: 70%

Defensa ante mesa de evaluadores: 30%



"Tradición y Excelencia en la formación de Ingenieros"

SEDE, CAMPUS DE LA UNA, SAN LORENZO
FACULTAD DE INGENIERÍA
DEPARTAMENTO INGENIERÍA ELECTRÓNICA Y MECATRÓNICA
PROGRAMA DE ACTIVIDADES ACADÉMICAS
MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL

Código	MSCIA14
Nombre del Programa	MAESTRÍA EN CIENCIAS DE LA INTELIGENCIA ARTIFICIAL
Plan de estudios	2022
Periodo académico	CUARTO SEMESTRE



Universidad Nacional de Asunción

CONSEJO SUPERIOR UNIVERSITARIO

www.una.py

C. Elect.: sgeneral@rec.una.py

Telefax: 595 – 21 – 585540/3, 585546

CP: 2160, San Lorenzo – Paraguay

Campus de la UNA, San Lorenzo – Paraguay

Acta N° 3 (A.S. N° 3/15/02/2023)
Resolución N° 0057-00-2023

../(89)

Área	Extensión
Nombre de la actividad académica	Extensión Universitaria
Carga horaria semanal	No Aplica
Carga horaria total	30
Créditos académicos	1
Prerrequisitos	-

1. Fundamentación:

La extensión, función esencial de la universidad, es el conjunto de actividades que la institución realiza más allá del desenvolvimiento los programas de posgrado y de la investigación. De forma general el registro, realización y control de estas actividades se realizan mediante el Departamento de Extensión Académica de la FIUNA.

2. Objetivo General:

Divulgar los resultados de las investigaciones e implementar de proyectos colaborativos con el gobierno y la industria con el fin de mejorar la calidad de vida de la sociedad.

3. Contenidos:

Las actividades de extensión universitaria aquellas actividades académicas que tienen por objeto promover el desarrollo científico y tecnológico divulgando los resultados de la investigación realizadas; con el fin de crear una colaboración entre la Universidad, la industria, el gobierno y la Sociedad.

4. Metodología de trabajo:

Cada semestre se realizan exposiciones de trabajos de investigaciones y por otro lado de invita a profesionales del área de ciencia de datos que se desempeñan tanto en el sector público como privado para identificar las posibles oportunidades de colaboración

5. Actividades de evaluación:

Se registran las horas dedicadas a organizar, preparar y presentar los trabajos en las exposiciones de trabajos.

0057-02-2023 La presente Resolución tendrá vigencia a partir del **15 de febrero de 2023**.

Ing. Quim. **CRISTIAN DAVID CANTERO A.**
SECRETARIO GENERAL

Prof. Dra. **ZULLY VERA DE MOLINAS**
RECTORA Y PRESIDENTA

