



Programa de asignatura por competencias de educación superior

Sección I. Identificación del Curso

Tabla 1. Identificación de la Planificación del Curso.

Actualización:	Junio 07, 2022				
Carrera:	Ingeniería en Desarrollo de Software	Asignatura:	Machine learning		
Academia:	Ciencias Computacionales y Programación /	Clave:	19SDSIA02		
Módulo formativo:	No disponible	Seriación:	19SDSIA03 - Optimización		
Tipo de curso:	Presencial	Prerrequisito:	19SDSIA01 - Probabilidad y estadística para inteligencia artificial		
Semestre:	Séptimo	Créditos:	6.75	Horas semestre:	108 horas
Teoría:	2 horas	Práctica:	2 horas	Trabajo indpt.:	2 horas
				Total x semana:	6 horas

Sección II. Objetivos educacionales

Tabla 2. Objetivos educacionales

Objetivos educacionales		Criterios de desempeño	Indicadores
OE1	Los egresados gestionarán recursos relacionados con el desarrollo de software en alguna organización.	Los egresados podrán aplicar metodologías en el desarrollo de proyectos en el contexto laboral.	20% de los egresados aplicarán metodologías en el desarrollo de software en su contexto laboral.
OE2	Los egresados diseñarán e implementarán soluciones innovadoras mediante el uso de tecnologías de la información.	Los egresados participarán activamente en el ciclo de desarrollo e integración continuos	25% de los egresados desempeñarán labores de desarrollo e integración continuos.
OE3	Los egresados desarrollarán conocimiento especializado que les permite enfocarse en un área del conocimiento específico del desarrollo de software.	Los egresados desempeñarán actividades orientadas al aseguramiento de los activos de información de manera resiliente, la gestión de la infraestructura de redes y comunicaciones, o integrando hardware y software para crear soluciones IoT; así como el uso de inteligencia artificial para gestionar datos y reconocer patrones que determinen oportunidades de negocio en las organizaciones.	5% de los egresados desempeñarán labores en desarrollo de soluciones IoT.
OE5	Los egresados serán capaces de emprender un negocio basado en el desarrollo de un producto o servicio de tecnologías de la información, aportando valor a la generación de empleos e incrementar el bienestar económico y social, de forma ecológica y sustentable.	Los egresados serán capaces de emprender un negocio basado en el desarrollo propio de un producto o servicio de tecnologías de la información.	2% de los egresados tendrán participación en el acta constitutiva de una empresa creada a partir del desarrollo de software para ofrecer un producto o servicio.



Atributos de egreso de plan de estudios		Criterios de desempeño	Componentes
AE2	Aplicar y analizar procesos de diseño de ingeniería para generar una experiencia de usuario que asegure cubrir las necesidades como las expectativas de clientes y partes interesadas, utilizando y gestionando la infraestructura de red necesaria.	- Diseñará aplicaciones eficientes que usen algoritmos especiales de la teoría de autómatas y que cumplan con los principios de diseño de la ingeniería de software.	1. Introducción al Machine Learning. 1.1 Aplicaciones de Machine Learning. 1.2 Como aprenden las máquinas. 1.3 Asociaciones de aprendizaje. 1.4 Aprendizaje supervisado. 1.5 Aprendizaje no supervisado. 1.4 Representación de los datos (entradas). 1.7 Espacios de hipótesis. 1.8 Ordenamiento de las hipótesis. 1.9 Gestión, exploración y comprensión de datos. 1.10 Método LIME. 1.11 Regularización. 1. 12 Calibración de modelos.
AE3	Desarrollar una experimentación adecuada para recopilar, almacenar y analizar grandes cantidades de información basándose en el juicio ingenieril para crear productos o servicios innovadores mediados por software.	- Fragmentará un problema general, de tal modo que cada fragmento se pueda resolver mediante un algoritmo propio de la IA o ML.	2.1 Aprendizaje probabilístico y logística. 2.1.1 Predicción de datos. 2.1.2 El clasificador bayesiano óptimo. 2.1.3 Agrupamiento jerárquico. 2.1.4 Bagging. 2.1.5 Regresión lineal simple. 2.1.6 Regresión lineal múltiple. 2.1.7 Regresión lineal (Lasso) 2.1.8 Regresión lineal (Ridge) 2.1.9 Regresión logística. 2.1.10 Matriz de confusión. 2.1.11 Análisis discriminante lineal. 2.1.12 Análisis discriminante cuadrático.



Continuación: Tabla 2. Objetivos educacionales (continuación)

No.	Atributos de egreso de plan de estudios	Criterios de desempeño	Componentes
			2.2 Algunos algoritmos para aprendizaje supervisado. 2.2.1 Regresión logística. 2.2.2 Vecinos más cercanos. 2.2.3 Máquinas de vectores de soportes. 2.2.4 Árboles de decisión. 2.2.5 Bosques aleatorios. 2.3 Algunos ALGORITMOS para aprendizaje no Supervisado (agrupamiento y análisis de datos). 2.3.1 K-medias. 2.3.1.1 Medidas de similitudes. 2.3.1.2 Identificación del número de conglomerados. 2.3.1.3 Métricas de validación. Espectral. 2.3.2 Mezcla Gaussiana. 2.3.3 Reglas de asociación. 2.3.4 Mapas de Autoorganización. 2.3.5 El algoritmo Page Rank de Google. 3. Árboles de decisión. 3.1 Clasificación del árbol. 3.1.1 Requisitos y supuestos de los datos. 3.2 Interpretación de los resultados. 3.3 Predicción y Evaluación. 3.4 Construcción de un árbol.
AE6	Reconocer la mejora continua como parte de su desarrollo profesional para mantener un perfil actualizado en desarrollo de software para el diseño e implementación de productos y servicios basados en tecnologías con las tendencias emergentes.	- Mejorará las aplicaciones cumpliendo con los principios de diseño de la ingeniería de software.	4.1 REDES NEURONALES. 4.1.1 Arquitectura de una red. 4.1.2 Perceptrón. 4.1.3 Red convolucional multicapa. 4.1.4 Función de activación.



Continuación: Tabla 2. Objetivos educacionales (continuación)

No.	Atributos de egreso de plan de estudios	Criterios de desempeño	Componentes
			4.1.5 Back-propagation. 4.1.6 Red elástica. 4.1.7 Redes multicapa. 4.2 The Kernel Trick. 4.2.1 Kernels, forma de interpretar el conocimiento prioritario. 4.2.2 Caracterizando las funciones Kernel. 5. Aprendizaje por refuerzo. 5.1 ¿Qué es el Reinforcement Learning? 5.2 Diferencias con aprendizaje supervisado y no supervisado. 5.3 Componentes de RL. 5.4 Cómo funciona el RL? 5.5 Algoritmo Q-Learning.

Sección III. Atributos de la asignatura

Tabla 3. Atributos de la asignatura

Problema a resolver		
Analizar, diseñar y codificar algoritmos para automatizar algún proceso de evaluación de datos.		
Atributos (competencia específica) de la asignatura		
Ser capaz de proponer, entender y analizar un algoritmo que resuelva alguna necesidad en cuanto a procesamiento de datos se refiera.		
Aportación a la competencia específica		Aportación a las competencias transversales
Saber	Saber hacer	Saber Ser
<ul style="list-style-type: none"> - Conocer los tipos de datos y algoritmos que se pueden llegar a usar en una aplicación de software. - Conocer las estructuras de datos que se pueden llegar a aplicar en el desarrollo de software. 	<ul style="list-style-type: none"> - Analizar problemas de la vida cotidiana con el fin de diseñar un modelo computacional que lo represente. - Implementar algoritmos para resolver problemas de índole cotidiana basados en un modelo computacional. 	<ul style="list-style-type: none"> - El estudiante tiene el compromiso de tratar con discreción y no compartir los datos personales, ya que en la aplicación de ML es necesario el análisis y recolección de datos, los cuales, dependiendo de la aplicación, pueden ser considerados como personales. - El alumno tendrá la capacidad para transmitir su idea a otros miembros del equipo de trabajo. - El alumno será propositivo, de acuerdo a sus conocimientos, con respecto al mejor tipo de aprendizaje máquina, para un problema en específico. - El alumno entregará a tiempo los módulos del algoritmo que se le hallan propuesto a él y a los otros miembros del equipo de trabajo. - El alumno expresará, con fundamentos y respeto, sus puntos de vista, de acuerdo al análisis de un problema en el ML.
Producto integrador de la asignatura, considerando los avances por unidad		
Desarrollo de una aplicación la cual tendrá como propósito el diagnóstico temprano de alguna enfermedad.		

Sección IV. Desglose específico por cada unidad formativa

Tabla 4.1. Desglose específico de la unidad "Introducción al Machine Learning y conceptos generales."

Número y nombre de la unidad: 1. Introducción al Machine Learning y conceptos generales.							
Tiempo y porcentaje para esta unidad:		Teoría:	10 horas	Práctica:	12 horas	Porcentaje del programa:	30.56%
Aprendizajes esperados:		Comprender el tipo de problemas que se pueden resolver usando ML, de tal modo que pueda decidir sobre que algoritmo es pertinente usar para el problema en cuestión.					
Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad (Evidencia de aprendizaje de la unidad)			
1. Introducción al Machine Learning. 1.1 Aplicaciones de Machine Learning. 1.2 Cómo aprenden las máquinas. 1.3 Asociaciones de aprendizaje. 1.4 Aprendizaje supervisado. 1.5 Aprendizaje no supervisado. 1.4 Representación de los datos (entradas) 1.7 Espacios de hipótesis. 1.8 Ordenamiento de las hipótesis. 1.9 Gestión, exploración y comprensión de datos. 1.10 Método LIME. 1.11 Regularización. 1. 12 Calibración de modelos.	Saber: - Discernir entre los distintos tipos de datos informáticos que pueden intervenir en una aplicación de software. Saber hacer: - Proponer una o varias soluciones a través de algoritmos y pseudocódigos. Ser: El alumno tendrá la capacidad para transmitir su idea a otros miembros del equipo de trabajo.	- Debe generar un debate sobre los distintos tipos de datos que se usan en la vida cotidiana, lo cual lleve a generar un debate colaborativo. - Se debe llevar a cabo analogías de la vida cotidiana en la resolución de problemas y los procesos para resolver problemas computacionalmente. - Podrá usar uno o varios casos de uso para ejemplificar la importancia de los algoritmos en el machine learning y los distintos elementos que intervienen en el	Evaluación formativa: - Ejercicios y actividades. Evaluación sumativa: - Para la evaluación se deberá hacer una serie de exámenes, entre escritos y orales. Todas las evaluaciones podrán ser en equipo o individuales. - Las evaluaciones orales podrán abordar preguntas específicas de sus trabajos entregados en el portafolio de evidencias.	Portafolio de evidencias: - Prácticas de laboratorio. - Ejercicios y actividades.			



Continuación: Tabla 4.1. Desglose específico de la unidad "Introducción al Machine Learning y conceptos generales."

Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad
		desarrollo de un programa. - Cada participante debe generar su portafolio de evidencias, tanto de las notas personales como de los distintos ejercicios de programación.		
Bibliografía				
- Shalev-Shwartz, S.; Ben-David, S. (2014). Understanding Machine Learning. Cambridge University Press. - Müller, A. C.; Guido, S. (2016). Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media.				

Sección IV. Desglose específico por cada unidad formativa

Tabla 4.2. Desglose específico de la unidad " Tipos de aprendizaje."

Número y nombre de la unidad: 2. Tipos de aprendizaje.				
Tiempo y porcentaje para esta unidad:		Teoría: 10 horas	Práctica: 14 horas	Porcentaje del programa: 33.33%
Aprendizajes esperados:		Conocer algunos de los algoritmos que se usan en ML para el tipo de datos probabilístico, con el fin de tener la capacidad intelectual de sugerir y/o aplicar alguno de ellos en la automatización de toma de decisiones.		
Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad (Evidencia de aprendizaje de la unidad)
2.1 Aprendizaje probabilístico y logística. 2.1.1 Predicción de datos. 2.1.2 El clasificador bayesiano óptimo. 2.1.3 Agrupamiento jerárquico. 2.1.4 Bagging. 2.1.5 Regresión lineal simple. 2.1.6 Regresión lineal múltiple. 2.1.7 Regresión lineal (Lasso) 2.1.8 Regresión lineal (Ridge) 2.1.9 Regresión logística. 2.1.10 Matriz de confusión. 2.1.11 Análisis discriminante lineal. 2.1.12 Análisis discriminante cuadrático. 2.2 Algunos algoritmos para aprendizaje supervisado. 2.2.1 Regresión logística. 2.2.2 Vecinos más cercanos.	Saber: - Conocer los distintos tipos de aprendizaje en ML para la resolución de un problema específico. Saber hacer: - Implementar alguno de los algoritmos para casos particulares de la resolución de problemas en la ingeniería del desarrollo de software por medio de ML - Usar los distintos tipos de aprendizaje en ML para la resolución de un problema específico.	- Cada participante debe generar su portafolio de evidencias, tanto de las notas personales como de los distintos ejercicios de programación. - Se debe dar a conocer un problema o situación en la cual se pueda aplicar la programación y que dé como resultado la solución del problema en cuestión. - Para corroborar los aprendizajes se puede hacer uso de un aula invertida.	Evaluación formativa: - Ejercicios y actividades. Evaluación sumativa: - Para la evaluación se deberá hacer una serie de exámenes, entre escritos y orales. Todas las evaluaciones podrán ser en equipo o individuales. - Las evaluaciones orales podrán abordar preguntas específicas de sus trabajos entregados en el portafolio de evidencias.	Portafolio de evidencias: - Prácticas de laboratorio. - Ejercicios y actividades.



Continuación: Tabla 4.2. Desglose específico de la unidad " Tipos de aprendizaje."

Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad
2.2.3 Máquinas de vectores de soportes. 2.2.4 Árboles de decisión. 2.2.5 Bosques aleatorios. 2.3 Algunos ALGORITMOS para aprendizaje no Supervisado (agrupamiento y análisis de datos). 2.3.1 K-medias. 2.3.1.1 Medidas de similitudes. 2.3.1.2 Identificación del número de conglomerados. 2.3.1.3 Métricas de validación. Espectral. 2.3.2 Mezcla Gaussiana. 2.3.3 Reglas de asociación. 2.3.4 Mapas de Autoorganización. 2.3.5 El algoritmo Page Rank de Google.	Ser: El alumno será propositivo, de acuerdo a sus conocimientos, con respecto al mejor tipo de aprendizaje máquina, para un problema en específico.			
Bibliografía				
- Shalev-Shwartz, S.; Ben-David, S. (2014). Understanding Machine Learning. Cambridge University Press. - Müller, A. C.; Guido, S. (2016). Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media.				

Sección IV. Desglose específico por cada unidad formativa

Tabla 4.3. Desglose específico de la unidad "Árboles de decisión"

Número y nombre de la unidad: 3. Árboles de decisión				
Tiempo y porcentaje para esta unidad:		Teoría: 4 horas	Práctica: 4 horas	Porcentaje del programa: 11.11%
Aprendizajes esperados:		Conocer los distintos problemas en donde se pueda aplicar algún algoritmo de árboles de decisión con el fin de generar una aplicación que asegure que los datos de la resolución puedan ser tomados como fiables.		
Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad (Evidencia de aprendizaje de la unidad)
3. Árboles de decisión. 3.1 Clasificación del árbol. 3.1.1 Requisitos y supuestos de los datos. 3.2 Interpretación de los resultados. 3.3 Predicción y Evaluación. 3.4 Construcción de un árbol.	Saber: - Conocer los problemas en donde se pueda aplicar algún algoritmo de árboles de decisión. Saber hacer: - Implementará alguno de los algoritmos para casos particulares de la resolución de problemas en el aprendizaje máquina. - Ser capaz de estructurar un programa de acuerdo al algoritmo desarrollado. Ser: El alumno entregará a tiempo los módulos del algoritmo que se le hallan	- Cada participante debe generar su portafolio de evidencias, tanto de las notas personales como de los distintos ejercicios de programación. - Se debe dar a conocer un problema o situación en la cual se pueda aplicar la programación y que dé como resultado la solución del problema en cuestión. - Para corroborar los aprendizajes se puede hacer uso de un aula invertida.	Evaluación formativa: - Ejercicios y actividades. Evaluación sumativa: - Para la evaluación se deberá hacer una serie de exámenes, entre escritos y orales. Todas las evaluaciones podrán ser en equipo o individuales. - Las evaluaciones orales podrán abordar preguntas específicas de sus trabajos entregados en el portafolio de evidencias. - Proyecto.	Portafolio de evidencias: - Prácticas de laboratorio. - Ejercicios y actividades. - Proyecto.



Continuación: Tabla 4.3. Desglose específico de la unidad "Árboles de decisión"

Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad
	propuesto a él y a los otros miembros del equipo de trabajo.			
Bibliografía				
- Shalev-Shwartz, S.; Ben-David, S. (2014). Understanding Machine Learning. Cambridge University Press. - Müller, A. C.; Guido, S. (2016). Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media.				

Sección IV. Desglose específico por cada unidad formativa

Tabla 4.4. Desglose específico de la unidad "Redes Neuronales."

Número y nombre de la unidad: 4. Redes Neuronales.							
Tiempo y porcentaje para esta unidad:		Teoría:	2 horas	Práctica:	6 horas	Porcentaje del programa:	11.11%
Aprendizajes esperados:		Conocer los distintos problemas en donde se pueda aplicar algún algoritmo de redes neuronales con el fin de generar una aplicación que asegure que los datos de la resolución puedan ser tomados como fiables.					
Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad (Evidencia de aprendizaje de la unidad)			
4.1 REDES NEURONALES. 4.1.1 Arquitectura de una red. 4.1.2 Perceptrón. 4.1.3 Red convolucional multicapa. 4.1.4 Función de activación. 4.1.5 Back-propagation. 4.1.6 Red elástica. 4.1.7 Redes multicapa. 4.2 The Kernel Trick. 4.2.1 Kernels, forma de interpretar el conocimiento prioritario. 4.2.2 Caracterizando las funciones Kernel.	Saber: - Explicar las diferencias entre el uso de las redes neuronales y los arboles de decisión, con respecto a la elección del algoritmo más adecuado para un problema en específico. Saber hacer: - Implementar alguno de los algoritmos de redes neuronales en un problema específico del campo del ML.	- Cada participante debe generar su portafolio de evidencias, tanto de las notas personales como de los distintos ejercicios de programación. - Se debe dar a conocer un problema o situación en la cual se pueda aplicar la programación y que dé como resultado la solución del problema en cuestión. - Para corroborar los aprendizajes se puede hacer uso de un aula invertida.	Evaluación formativa: - Ejercicios y actividades. Evaluación sumativa: - Para la evaluación se deberá hacer una serie de exámenes, entre escritos y orales. Todas las evaluaciones podrán ser en equipo o individuales. - Las evaluaciones orales podrán abordar preguntas específicas de sus trabajos entregados en el portafolio de evidencias. - Proyecto.	Portafolio de evidencias: - Prácticas de laboratorio. - Ejercicios y actividades. - Proyecto.			



Continuación: Tabla 4.4. Desglose específico de la unidad "Redes Neuronales."

Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad
	Ser: El alumno expresará, con fundamentos y respeto, sus puntos de vista, de acuerdo al análisis de un problema en el ML.			
Bibliografía				
- Shalev-Shwartz, S.; Ben-David, S. (2014). Understanding Machine Learning. Cambridge University Press. - Müller, A. C.; Guido, S. (2016). Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media.				

Sección IV. Desglose específico por cada unidad formativa

Tabla 4.5. Desglose específico de la unidad "Aprendizaje por refuerzo."

Número y nombre de la unidad: 5. Aprendizaje por refuerzo.							
Tiempo y porcentaje para esta unidad:		Teoría:	5 horas	Práctica:	5 horas	Porcentaje del programa:	13.89%
Aprendizajes esperados:		Poder aplicar las distintas formas de aprendizaje con el fin de generar aplicaciones que sean capaces de aprender y proporcionar una respuesta al problema a automatizar.					
Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad (Evidencia de aprendizaje de la unidad)			
5. Aprendizaje por refuerzo. 5.1 ¿Qué es el Reinforcement Learning? 5.2 Diferencias con aprendizaje supervisado y no supervisado. 5.3 Componentes de RL. 5.4 Cómo funciona el RL? 5.5 Algoritmo Q-Learning.	Saber: - Diferenciar las distintas formas de aprendizaje con el fin de aplicar alguno de los algoritmos de acuerdo al problema a automatizar. Saber hacer: - Implementar alguno de los algoritmos para casos particulares de la resolución de problemas en el aprendizaje máquina. Ser: El alumno entregará a tiempo los	- Cada participante debe generar su portafolio de evidencias, tanto de las notas personales como de los distintos ejercicios de programación que se lleven a cabo como los de tarea. - Se debe dar a conocer un problema o situación en la cual se pueda aplicar alguno de los algoritmos en machine Learning y que dé como resultado la solución del problema en cuestión. - Para corroborar los aprendizajes se puede hacer uso de un aula invertida.	Evaluación formativa: - Ejercicios y actividades. Evaluación sumativa: - Para la evaluación se deberá hacer una serie de exámenes, entre escritos y orales. Todas las evaluaciones podrán ser en equipo o individuales. - Las evaluaciones orales podrán abordar preguntas específicas de sus trabajos entregados en el portafolio de evidencias. - Proyecto.	- Portafolio de evidencias. - Proyecto del curso.			



Continuación: Tabla 4.5. Desglose específico de la unidad "Aprendizaje por refuerzo."

Temas y subtemas (secuencia)	Criterios de desempeño	Estrategias didácticas	Estrategias de evaluación	Producto Integrador de la unidad
	módulos del algoritmo que se le hallan propuesto a él y a los otros miembros del equipo de trabajo.			
Bibliografía				
<p>- Shalev-Shwartz, S.; Ben-David, S. (2014). Understanding Machine Learning. Cambridge University Press.</p> <p>- Müller, A. C.; Guido, S. (2016). Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media.</p>				



V. Perfil docente

Tabla 5. Descripción del perfil docente

Perfil deseable docente para impartir la asignatura
<p>Carrera(s): - Maestría o Ingeniería en Sistemas, titulado, o carrera afín. o carrera afín</p> <ul style="list-style-type: none">- Con experiencia docente o en el campo deseable de 2 años. Manejo de TIC´s. Con habilidades pedagógicas y uso de metodologías alternativas de enseñanza.- Experiencia mínima de dos años- Mínimo Licenciatura o superior