

Máster Título Propio

Deep Learning



Máster Título Propio Deep Learning

- » Modalidad: **online**
- » Duración: **12 meses**
- » Titulación: **TECH Universidad ULAC**
- » Acreditación: **60 ECTS**
- » Horario: **a tu ritmo**
- » Exámenes: **online**

Acceso web: www.techtitute.com/inteligencia-artificial/master/master-deep-learning



Índice

01

Presentación

pág. 4

02

Objetivos

pág. 8

03

Competencias

pág. 14

04

Dirección del curso

pág. 18

05

Estructura y contenido

pág. 22

06

Metodología

pág. 32

07

Titulación

pág. 40

01

Presentación

El Deep Learning ha supuesto durante los últimos años una revolución tecnológica. Esta variante de la Inteligencia Artificial se centra en el entrenamiento de Redes Neuronales profundas para aprender representaciones jerárquicas de datos. Además, posee un amplio abanico de aplicaciones, siendo una muestra el mundo de las finanzas. Así pues, los expertos son capaces de detectar fraudes, analizar los riesgos e incluso predecir precios de acciones. No es de extrañar, por lo tanto, que cada vez más personas decidan especializarse en este campo de especialización. Para dar respuesta a este requerimiento, TECH desarrolla una capacitación que abordará en detalle las particularidades del Aprendizaje Automático Profundo. Todo en un formato 100% online, para brindar una mayor comodidad a los estudiantes.





rotationPitch 20.0
rotationYawDegree 153.0
shotNumber 130
AFO_vjCarRear.0 x: -0.4, y: 5.4, z: 1.8, dist: 5.7
OBS.RedCC.3 x: -5.7, y: 15.3, z: 0.3, h: 0.7, r: 0.7
OBS.RedCC.4 x: -4.1, y: 21.6, z: -0.5, h: 0.7, r: 0.7
OBS.RedCC.5 x: -5.0, y: 9.4, z: 0.2, h: 0.7, r: 0.7
OBS.RedCC.7 x: -3.1, y: 9.5, z: 0.2, h: 0.7, r: 0.7

66

Aplicarás a tus proyectos las técnicas más innovadoras del Aprendizaje profundo gracias a este Máster Título Propio 100% online"

El TensorFlow se ha transformado en la herramienta más importante para implementar y entrenar modelos de Aprendizaje Profundo. Los desarrolladores emplean tanto su variedad de instrumentos como bibliotecas para entrenar modelos que realicen tareas automáticas de detección de objetos, clasificación y procesamiento del lenguaje natural. En esta misma línea, esta plataforma es provechosa para detectar anomalías en datos, lo que es esencial en ámbitos como la seguridad cibernética, el mantenimiento predictivo y el control de calidad. Sin embargo, su uso puede implicar una serie de retos para los profesionales, entre los que destacan la selección de la arquitectura de red neuronal adecuada.

Ante esta situación, TECH implementa un Máster Título Propio que proporcionará a los expertos un enfoque integral sobre el *Deep Learning*. Elaborado por expertos en la materia, el plan de estudios ahondará en los fundamentos matemáticos y principios del Aprendizaje Profundo. Esto les permitirá a los egresados construir Redes Neuronales dirigidas al procesamiento de información que implican reconocimiento de patrones, tomas de decisiones y aprendizaje a partir de datos. Asimismo, el temario profundizará en el *Reinforcement Learning* teniendo en cuenta factores como la optimización de las recompensas y la búsqueda de política. Por otra parte, los materiales didácticos ofrecerán técnicas avanzadas de optimización y visualización de resultados.

En cuanto al formato de la titulación universitaria, esta se imparte a través de una metodología 100% online para que los egresados puedan completar el programa con comodidad. Para acceder a los contenidos académicos tan solo necesitarán un dispositivo electrónico con acceso a Internet, puesto que los horarios y cronogramas evaluativos se planifican de manera individual. Por otro lado, el temario se apoyará en el novedoso sistema de enseñanza del *Relearning*, del cual TECH es pionera. Este sistema de aprendizaje consiste en la reiteración de los aspectos claves para garantizar el dominio de sus diferentes aspectos.

Este **Máster Título Propio en Deep Learning** contiene el programa educativo más completo y actualizado del mercado. Sus características más destacadas son:

- El desarrollo de casos prácticos presentados por expertos en *Data Engineer* y *Data Scientist*
- Los contenidos gráficos, esquemáticos y eminentemente prácticos con los que está concebido recogen una información técnica y práctica sobre aquellas disciplinas indispensables para el ejercicio profesional
- Los ejercicios prácticos donde realizar el proceso de autoevaluación para mejorar el aprendizaje
- Su especial hincapié en metodologías innovadoras
- Las lecciones teóricas, preguntas al experto, foros de discusión de temas controvertidos y trabajos de reflexión individual
- La disponibilidad de acceso a los contenidos desde cualquier dispositivo fijo o portátil con conexión a internet



Estudia por medio de innovadores formatos didácticos multimedia que optimizarán tu proceso de actualización en Deep Learning"

“

¿Buscas enriquecer tu praxis con las técnicas de optimización de gradientes más avanzadas? Lógralo con este programa en tan solo 12 meses”


El programa incluye en su cuadro docente a profesionales del sector que vierten en esta capacitación la experiencia de su trabajo, además de reconocidos especialistas de sociedades de referencia y universidades de prestigio.

Su contenido multimedia, elaborado con la última tecnología educativa, permitirá al profesional un aprendizaje situado y contextual, es decir, un entorno simulado que proporcionará una capacitación inmersiva programada para entrenarse ante situaciones reales.

El diseño de este programa se centra en el Aprendizaje Basado en Problemas, mediante el cual el profesional deberá tratar de resolver las distintas situaciones de práctica profesional que se le planteen a lo largo del curso académico. Para ello, contará con la ayuda de un novedoso sistema de vídeo interactivo realizado por reconocidos expertos.

Profundizarás en los Backward Pass para calcular los gradientes de la función de pérdida con respecto a los parámetros de la red.

Gracias a la metodología del Relearning, tendrás libertad para planificar tanto tus horarios de estudio como cronogramas educativos.



02

Objetivos

Gracias a este Máster Título Propio, los egresados desarrollarán sus habilidades y conocimientos en el campo del Aprendizaje Profundo e Inteligencia Artificial. De esta forma, implementarán las técnicas más avanzadas de *Deep Learning* en sus proyectos para mejorar el rendimiento de los modelos en tareas específicas. Asimismo, los expertos serán capaces de desarrollar sistemas inteligentes que puedan realizar automáticamente tareas como el reconocimiento de patrones en imágenes, análisis de sentimientos en texto o detección de anomalías en datos.



“

*Un título universitario diseñado con base
en las últimas tendencias en Deep Learning
para garantizarte un aprendizaje exitoso”*



Objetivos generales

- Fundamentar los conceptos clave de las funciones matemáticas y sus derivadas
 - Aplicar estos principios a los algoritmos de aprendizaje profundo para aprender automáticamente
 - Examinar los conceptos clave del Aprendizaje Supervisado y cómo se aplican a los modelos de redes neuronales
 - Analizar el entrenamiento, la evaluación y el análisis de los modelos de redes neuronales
 - Fundamentar los conceptos clave y las principales aplicaciones del aprendizaje profundo
 - Implementar y optimizar redes neuronales con Keras
 - Desarrollar conocimiento especializado sobre el entrenamiento de redes neuronales profundas
 - Analizar los mecanismos de optimización y regularización necesarios para el entrenamiento de redes profundas



Objetivos específicos

Módulo 1. Fundamentos Matemáticos de Deep Learning

- Desarrollar la regla de la cadena para calcular derivadas de funciones anidadas
- Analizar cómo se crean nuevas funciones a partir de funciones existentes y cómo se calculan las derivadas de las mismas
- Examinar el concepto del *Backward Pass* y cómo se aplican las derivadas de las funciones vectoriales para aprender automáticamente
- Aprender acerca de cómo usar TensorFlow para construir modelos personalizados
- Comprender cómo cargar y procesar datos utilizando herramientas de TensorFlow
- Fundamentar los conceptos clave del procesamiento del lenguaje natural NLP con RNN y mecanismos de atención
- Explorar la funcionalidad de las librerías de *transformers* de Hugging Face y otras herramientas de procesamiento de lenguaje natural para aplicar a problemas de visión
- Aprender a construir y entrenar modelos de autoencoders, GANs y modelos de difusión
- Comprender cómo los autoencoders pueden utilizarse para codificar datos eficientemente

Módulo 2. Principios de Deep Learning

- Analizar el funcionamiento de la regresión lineal y cómo puede ser aplicada a los modelos de redes neuronales
- Fundamentar la optimización de los hiperparámetros para mejorar el rendimiento de los modelos de redes neuronales
- Determinar cómo se puede evaluar el rendimiento de los modelos de redes neuronales mediante el uso del conjunto de entrenamiento y el conjunto de prueba

Módulo 3. Las Redes Neuronales, base de Deep Learning

- Analizar la arquitectura de las redes neuronales y sus principios de funcionamiento
- Determinar cómo se pueden aplicar las redes neuronales a una variedad de problemas
- Establecer cómo optimizar el rendimiento de los modelos de aprendizaje profundo mediante el ajuste de los hiperparámetros

Módulo 4. Entrenamiento de Redes Neuronales Profundas

- Analizar los problemas de gradiente y cómo se pueden evitar
- Determinar cómo reutilizar capas preentrenadas para entrenar redes neuronales profundas
- Establecer cómo programar la tasa de aprendizaje para obtener los mejores resultados

Módulo 5. Personalización de Modelos y Entrenamientos con TensorFlow

- Determinar cómo usar la API de TensorFlow para definir funciones y gráficos personalizados
- Fundamentar el uso de la API tf.data para cargar y preprocesar los datos de manera eficiente
- Discutir el proyecto TensorFlow Datasets y cómo se puede usar para facilitar el acceso a conjuntos de datos preprocesados

Módulo 6. Deep Computer Vision con Redes Neuronales Convolucionales

- Explorar y entender cómo funcionan las capas convolucionales y de agrupación para la arquitectura Visual Cortex
- Desarrollar arquitecturas CNN con Keras
- Usar modelos preentrenados de Keras para clasificación, localización, detección y seguimiento de objetos, así como para la segmentación semántica

Módulo 7. Secuencias de procesamiento utilizando RNN y CNN

- Analizar la arquitectura de las neuronas y capas recurrentes
- Examinar los diversos algoritmos de entrenamiento para el entrenamiento de modelos RNN
- Evaluar el desempeño de los modelos RNN utilizando métricas de exactitud y sensibilidad

Módulo 8. Procesamiento del Lenguaje Natural NLP con RNN y Atención

- Generar texto utilizando redes neuronales recurrentes
- Entrenar una red codificador-decodificador para realizar traducción automática neuronal
- Desarrollar una aplicación práctica de procesamiento del lenguaje natural con RNN y atención

Módulo 9. Autoencoders, GANs, y Modelos de Difusión

- Implementar técnicas de PCA con un codificador automático lineal incompleto
- Utilizar autocodificadores convolucionales y variacionales para mejorar los resultados de los autoencoders
- Analizar cómo las GANs y los modelos de difusión pueden generar imágenes nuevas y realistas

Módulo 10. Reinforcement Learning

- Utilizar gradientes para optimizar la política de un agente
- Evaluar el uso de redes neuronales para mejorar la precisión de un agente al tomar decisiones
- Implementar diferentes algoritmos de refuerzo para mejorar el rendimiento de un agente






“

*Una experiencia de
capacitación clave, única
y decisiva que impulsará
tu desarrollo profesional”*

03

Competencias

Por medio del Máster Título Propio, los egresados adquirirán nuevas destrezas para enfrentarse con éxito a los desafíos que presenta la Inteligencia Artificial. Tras la finalización de la titulación universitaria, los profesionales dominarán la utilización de herramientas de TensorFlow para la manipulación de datos. Asimismo, los expertos le sacarán el máximo provecho al entrenamiento de Redes Neuronales Profundas para solucionar problemas complejos y crear modelos precisos. De esta forma, llevarán a cabo propuestas innovadoras para destacar en un sector tecnológico en pleno auge.





66

Adquirirás destrezas avanzadas
para implementar en tus proyectos
la arquitectura Visual Cortex"

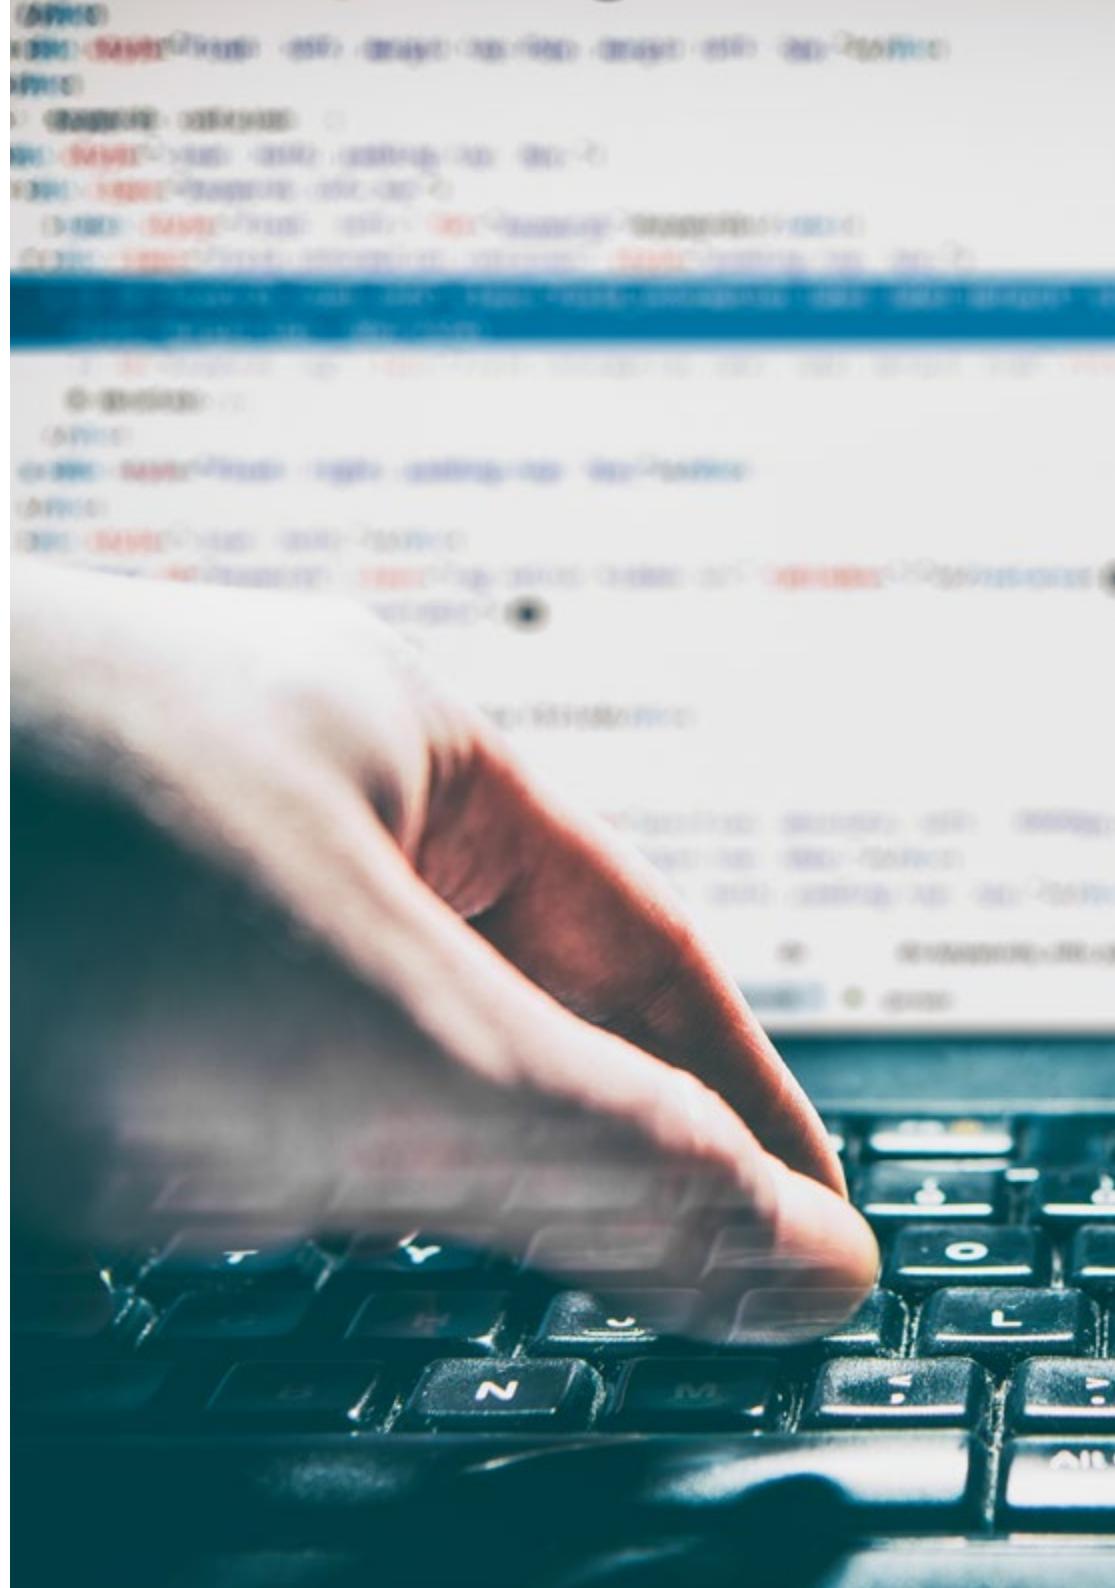


Competencias generales

- Implementar arquitectura Visual Cortex
- Utilizar modelos preentrenados de Keras para el aprendizaje por transferencia y otras tareas de visión por computadora
- Dominar la Red Neuronal Recurrente (RNN)
- Entrenar y evaluar un modelo RNN para la predicción de series de tiempo
- Mejorar la capacidad de un agente para tomar decisiones óptimas en un entorno
- Aumentar la eficiencia de un agente al aprender con recompensas

“

Manejará la herramienta TensorFlow para manipular los datos y crearás modelos de aprendizaje automático de gran nivel”





Competencias específicas

- Resolver problemas con datos, lo que implica mejorar procesos existentes y desarrollar nuevos procesos mediante el uso de herramientas tecnológicas adecuadas
- Implementar proyectos y tareas basadas en datos
- Utilizar métricas como la precisión, la exactitud y el error de clasificación
- Optimizar los parámetros de una red neuronal
- Construir modelos personalizados utilizando la API de TensorFlow
- Implementar con Keras tareas como la clasificación, la localización, la detección y seguimiento de objetos, así como la segmentación semántica
- Generar imágenes nuevas y realistas
- Implementar *Deep Q-Learning* y variantes de *Deep Q-Learning*
- Utilizar técnicas de optimización para el entrenamiento
- Entrenar con éxito redes neuronales profundas

04

Dirección del curso

Para ofrecer la máxima calidad educativa, TECH ha realizado un proceso riguroso de selección de cada uno de los docentes que integran sus titulaciones universitarias. Por eso, los alumnos que se adentren en este Máster Título Propio accederán a un plan de estudio diseñado por los mejores expertos en el campo del *Deep Learning*. Además, estos profesionales no solo se caracterizan por tener una sólida comprensión de la materia, sino que atesoran una amplia trayectoria laboral en prestigiosas instituciones. Todo ello permitirá a los estudiantes sumergirse en una experiencia inmersiva que le permitirá dar un salto en su carrera profesional.



“

La diversidad de talentos del cuadro docente te permitirá disfrutar de un ambiente de enseñanza totalmente dinámico y enriquecedor”

Dirección



D. Gil Contreras, Armando

- Lead Big Data Scientist en Jhonson Controls
- Data Scientist-Big Data en Opensistemas S.A.
- Auditor de Fondos en Creatividad y Tecnología S.A. (CYTSA)
- Auditor del Sector Público en PricewaterhouseCoopers Auditores
- Máster en *Data Science* por el Centro Universitario de Tecnología y Arte
- Máster MBA en Relaciones y Negocios Internacionales por el Centro de Estudios Financieros (CEF)
- Licenciatura en Economía por el Instituto Tecnológico de Santo Domingo

Profesores

Dña. Delgado Feliz, Benedit

- Asistente Administrativo y Operador De Vigilancia Electrónica en la Dirección Nacional de Control de Drogas (DNCD)
- Servicio al Cliente en Cáceres y Equipos
- Reclamaciones y Servicio al Cliente en Express Parcel Services (EPS)
- Especialista en Microsoft Office por la Escuela Nacional de Informática
- Comunicadora Social por la Universidad Católica Santo Domingo

D. Villar Valor, Javier

- Director y Socio Fundador de Impulsa2
- Chief Operations Officer (COO) en Summa Insurance Brokers
- Director de Transformación y Excelencia Operacional en Johnson Controls
- Máster en Coaching Profesional
- Executive MBA por la Emlyon Business School, Francia
- Máster en Gestión de la Calidad por EOI
- Ingeniería Informática por la Universidad Acción Pro-Educación y Cultura (UNAPEC)



D. Matos Rodríguez, Dionis

- ◆ *Data Engineer* en Wide Agency Sadexo
- ◆ *Data Consultant* en Tokiota
- ◆ *Data Engineer* en Devoteam
- ◆ *BI Developer* en Ibermática
- ◆ *Applications Engineer* en Johnson Controls
- ◆ *Database Developer* en Suncapital España
- ◆ *Senior Web Developer* en Deadlock Solutions
- ◆ *QA Analyst* en Metaconzept
- ◆ Máster en Big Data & Analytics por la EAE Business School
- ◆ Máster en Análisis y Diseño de Sistemas
- ◆ Licenciatura en Ingeniería Informática por la Universidad APEC

Dña. Gil de León, María

- ◆ Codirectora de Marketing y secretaria en RAÍZ Magazine
- ◆ Editora de Copia en Gauge Magazine
- ◆ Lectora de Stork Magazine por Emerson College
- ◆ Licenciatura en Escritura, Literatura y Publicación otorgada por el Emerson College

05

Estructura y contenido

Este Máster Título Propio ofrecerá a los alumnos una amplia gama de técnicas de *Deep Learning*, que elevarán sus horizontes profesionales a un nivel superior. Para conseguirlo, el itinerario académico profundizará en la codificación de modelos de aprendizaje profundo. De este modo, los egresados traducirán con eficacia los algoritmos y arquitecturas de redes neuronales profundas. Asimismo, el temario abordará en detalle el entrenamiento de redes neuronales profundas, así como la visualización de los resultados y la evaluación de los modelos de aprendizaje. También los estudiantes analizarán los principales Modelos *Transformers*, con el fin de manejarlos para generar traducciones automáticas.



66

Aplicarás a tus proyectos los principios del Deep Learning para resolver una variedad de problemas complejos en campos como el reconocimiento de imágenes”

Módulo 1. Fundamentos Matemáticos de Deep Learning

- 1.1. Funciones y Derivadas
 - 1.1.1. Funciones lineales
 - 1.1.2. Derivadas parciales
 - 1.1.3. Derivadas de orden superior
- 1.2. Funciones anidadas
 - 1.2.1. Funciones compuestas
 - 1.2.2. Funciones inversas
 - 1.2.3. Funciones recursivas
- 1.3. La regla de la cadena
 - 1.3.1. Derivadas de funciones anidadas
 - 1.3.2. Derivadas de funciones compuestas
 - 1.3.3. Derivadas de funciones inversas
- 1.4. Funciones con múltiples entradas
 - 1.4.1. Funciones de varias variables
 - 1.4.2. Funciones vectoriales
 - 1.4.3. Funciones matriciales
- 1.5. Derivadas de funciones con entradas múltiples
 - 1.5.1. Derivadas parciales
 - 1.5.2. Derivadas direccionales
 - 1.5.3. Derivadas mixtas
- 1.6. Funciones con múltiples entradas vectoriales
 - 1.6.1. Funciones vectoriales lineales
 - 1.6.2. Funciones vectoriales no lineales
 - 1.6.3. Funciones vectoriales de matriz
- 1.7. Creación de nuevas funciones a partir de funciones existentes
 - 1.7.1. Suma de funciones
 - 1.7.2. Producto de funciones
 - 1.7.3. Composición de funciones



- 1.8. Derivadas de funciones con múltiples entradas vectoriales
 - 1.8.1. Derivadas de funciones lineales
 - 1.8.2. Derivadas de funciones no lineales
 - 1.8.3. Derivadas de funciones compuestas
- 1.9. Funciones vectoriales y sus derivadas: Un paso más allá
 - 1.9.1. Derivadas direccionales
 - 1.9.2. Derivadas mixtas
 - 1.9.3. Derivadas matriciales
- 1.10. El *Backward Pass*
 - 1.10.1. Propagación de errores
 - 1.10.2. Aplicación de reglas de actualización
 - 1.10.3. Optimización de parámetros

Módulo 2. Principios de Deep Learning

- 2.1. El Aprendizaje Supervisado
 - 2.1.1. Máquinas de aprendizaje supervisado
 - 2.1.2. Usos del aprendizaje supervisado
 - 2.1.3. Diferencias entre aprendizaje supervisado y no supervisado
- 2.2. Modelos de aprendizaje supervisado
 - 2.2.1. Modelos lineales
 - 2.2.2. Modelos de árboles de decisión
 - 2.2.3. Modelos de redes neuronales
- 2.3. Regresión lineal
 - 2.3.1. Regresión lineal simple
 - 2.3.2. Regresión lineal múltiple
 - 2.3.3. Análisis de regresión
- 2.4. Entrenamiento del modelo
 - 2.4.1. *Batch Learning*
 - 2.4.2. *Online Learning*
 - 2.4.3. Métodos de Optimización
- 2.5. Evaluación del modelo: Conjunto de entrenamiento versus conjunto de prueba
 - 2.5.1. Métricas de evaluación
 - 2.5.2. Validación cruzada
 - 2.5.3. Comparación de los conjuntos de datos

- 2.6. Evaluación del modelo: El código
 - 2.6.1. Generación de predicciones
 - 2.6.2. Análisis de errores
 - 2.6.3. Métricas de evaluación
- 2.7. Análisis de las variables
 - 2.7.1. Identificación de variables relevantes
 - 2.7.2. Análisis de correlación
 - 2.7.3. Análisis de regresión
- 2.8. Explicabilidad de los modelos de redes neuronales
 - 2.8.1. Modelos interpretables
 - 2.8.2. Métodos de visualización
 - 2.8.3. Métodos de evaluación
- 2.9. Optimización
 - 2.9.1. Métodos de optimización
 - 2.9.2. Técnicas de regularización
 - 2.9.3. El uso de gráficos
- 2.10. Hiperparámetros
 - 2.10.1. Selección de hiperparámetros
 - 2.10.2. Búsqueda de parámetros
 - 2.10.3. Ajuste de hiperparámetros

Módulo 3. Las redes neuronales, base de Deep Learning

- 3.1. Aprendizaje Profundo
 - 3.1.1. Tipos de aprendizaje profundo
 - 3.1.2. Aplicaciones del aprendizaje profundo
 - 3.1.3. Ventajas y desventajas del aprendizaje profundo
- 3.2. Operaciones
 - 3.2.1. Suma
 - 3.2.2. Producto
 - 3.2.3. Traslado
- 3.3. Capas
 - 3.3.1. Capa de entrada
 - 3.3.2. Capa oculta
 - 3.3.3. Capa de salida

- 3.4. Unión de Capas y Operaciones
 - 3.4.1. Diseño de arquitecturas
 - 3.4.2. Conexión entre capas
 - 3.4.3. Propagación hacia adelante
- 3.5. Construcción de la primera red neuronal
 - 3.5.1. Diseño de la red
 - 3.5.2. Establecer los pesos
 - 3.5.3. Entrenamiento de la red
- 3.6. Entrenador y Optimizador
 - 3.6.1. Selección del optimizador
 - 3.6.2. Establecimiento de una función de pérdida
 - 3.6.3. Establecimiento de una métrica
- 3.7. Aplicación de los Principios de las Redes Neuronales
 - 3.7.1. Funciones de activación
 - 3.7.2. Propagación hacia atrás
 - 3.7.3. Ajuste de los parámetros
- 3.8. De las neuronas biológicas a las artificiales
 - 3.8.1. Funcionamiento de una neurona biológica
 - 3.8.2. Transferencia de conocimiento a las neuronas artificiales
 - 3.8.3. Establecer relaciones entre ambas
- 3.9. Implementación de MLP (Perceptrón multicapa) con Keras
 - 3.9.1. Definición de la estructura de la red
 - 3.9.2. Compilación del modelo
 - 3.9.3. Entrenamiento del modelo
- 3.10. Hiperparámetros de Fine tuning de Redes Neuronales
 - 3.10.1. Selección de la función de activación
 - 3.10.2. Establecer el *learning rate*
 - 3.10.3. Ajuste de los pesos

Módulo 4. Entrenamiento de redes neuronales profundas

- 4.1. Problemas de Gradientes
 - 4.1.1. Técnicas de optimización de gradiente
 - 4.1.2. Gradientes Estocásticos
 - 4.1.3. Técnicas de inicialización de pesos
- 4.2. Reutilización de capas preentrenadas
 - 4.2.1. Entrenamiento de transferencia de aprendizaje
 - 4.2.2. Extracción de características
 - 4.2.3. Aprendizaje profundo
- 4.3. Optimizadores
 - 4.3.1. Optimizadores de descenso de gradiente estocástico
 - 4.3.2. Optimizadores Adam y RMSprop
 - 4.3.3. Optimizadores de momento
- 4.4. Programación de la tasa de aprendizaje
 - 4.4.1. Control de tasa de aprendizaje automático
 - 4.4.2. Ciclos de aprendizaje
 - 4.4.3. Términos de suavizado
- 4.5. Sobreajuste
 - 4.5.1. Validación cruzada
 - 4.5.2. Regularización
 - 4.5.3. Métricas de evaluación
- 4.6. Directrices Prácticas
 - 4.6.1. Diseño de modelos
 - 4.6.2. Selección de métricas y parámetros de evaluación
 - 4.6.3. Pruebas de hipótesis
- 4.7. *Transfer learning*
 - 4.7.1. Entrenamiento de transferencia de aprendizaje
 - 4.7.2. Extracción de características
 - 4.7.3. Aprendizaje profundo
- 4.8. *Data Augmentation*
 - 4.8.1. Transformaciones de imagen
 - 4.8.2. Generación de datos sintéticos
 - 4.8.3. Transformación de texto



- 4.9. Aplicación Práctica de *Transfer Learning*
 - 4.9.1. Entrenamiento de transferencia de aprendizaje
 - 4.9.2. Extracción de características
 - 4.9.3. Aprendizaje profundo
- 4.10. Regularización
 - 4.10.1. L1 y L2
 - 4.10.2. Regularización por máxima entropía
 - 4.10.3. Dropout

Módulo 5. Personalización de Modelos y entrenamiento con TensorFlow

- 5.1. TensorFlow
 - 5.1.1. Uso de la biblioteca TensorFlow
 - 5.1.2. Entrenamiento de modelos con TensorFlow
 - 5.1.3. Operaciones con gráficos en TensorFlow
- 5.2. TensorFlow y NumPy
 - 5.2.1. Entorno computacional NumPy para TensorFlow
 - 5.2.2. Utilización de los arrays NumPy con TensorFlow
 - 5.2.3. Operaciones NumPy para los gráficos de TensorFlow
 - 5.3. Personalización de modelos y algoritmos de entrenamiento
 - 5.3.1. Construcción de modelos personalizados con TensorFlow
 - 5.3.2. Gestión de parámetros de entrenamiento
 - 5.3.3. Utilización de técnicas de optimización para el entrenamiento
- 5.4. Funciones y gráficos de TensorFlow
 - 5.4.1. Funciones con TensorFlow
 - 5.4.2. Utilización de gráficos para el entrenamiento de modelos
 - 5.4.3. Optimización de gráficos con operaciones de TensorFlow
- 5.5. Carga y preprocesamiento de datos con TensorFlow
 - 5.5.1. Carga de conjuntos de datos con TensorFlow
 - 5.5.2. Preprocesamiento de datos con TensorFlow
 - 5.5.3. Utilización de herramientas de TensorFlow para la manipulación de datos
- 5.6. La API tf.data
 - 5.6.1. Utilización de la API tf.data para el procesamiento de datos
 - 5.6.2. Construcción de flujos de datos con tf.data
 - 5.6.3. Uso de la API tf.data para el entrenamiento de modelos

- 5.7. El formato TFRecord
 - 5.7.1. Utilización de la API TFRecord para la serialización de datos
 - 5.7.2. Carga de archivos TFRecord con TensorFlow
 - 5.7.3. Utilización de archivos TFRecord para el entrenamiento de modelos
- 5.8. Capas de preprocesamiento de Keras
 - 5.8.1. Utilización de la API de preprocesamiento de Keras
 - 5.8.2. Construcción de pipelined de preprocesamiento con Keras
 - 5.8.3. Uso de la API de preprocesamiento de Keras para el entrenamiento de modelos
- 5.9. El proyecto TensorFlow Datasets
 - 5.9.1. Utilización de TensorFlow Datasets para la carga de datos
 - 5.9.2. Preprocesamiento de datos con TensorFlow Datasets
 - 5.9.3. Uso de TensorFlow Datasets para el entrenamiento de modelos
- 5.10. Construcción de una Aplicación de *Deep Learning* con TensorFlow. Aplicación Práctica
 - 5.10.1. Construcción de una aplicación de *Deep Learning* con TensorFlow
 - 5.10.2. Entrenamiento de un modelo con TensorFlow
 - 5.10.3. Utilización de la aplicación para la predicción de resultados
- 6.5. Implementación de una CNN ResNet-34 usando Keras
 - 6.5.1. Inicialización de pesos
 - 6.5.2. Definición de la capa de entrada
 - 6.5.3. Definición de la salida
- 6.6. Uso de modelos preentrenados de Keras
 - 6.6.1. Características de los modelos preentrenados
 - 6.6.2. Usos de los modelos preentrenados
 - 6.6.3. Ventajas de los modelos preentrenados
- 6.7. Modelos preentrenados para el aprendizaje por transferencia
 - 6.7.1. El Aprendizaje por transferencia
 - 6.7.2. Proceso de aprendizaje por transferencia
 - 6.7.3. Ventajas del aprendizaje por transferencia
- 6.8. Clasificación y Localización en Deep Computer Vision
 - 6.8.1. Clasificación de imágenes
 - 6.8.2. Localización de objetos en imágenes
 - 6.8.3. Detección de objetos
- 6.9. Detección de objetos y seguimiento de objetos
 - 6.9.1. Métodos de detección de objetos
 - 6.9.2. Algoritmos de seguimiento de objetos
 - 6.9.3. Técnicas de rastreo y localización
- 6.10. Segmentación semántica
 - 6.10.1. Aprendizaje profundo para segmentación semántica
 - 6.10.2. Detección de bordes
 - 6.10.3. Métodos de segmentación basados en reglas

Módulo 6. Deep Computer Vision con Redes Neuronales Convolucionales

- 6.1. La Arquitectura Visual Cortex
 - 6.1.1. Funciones de la corteza visual
 - 6.1.2. Teorías de la visión computacional
 - 6.1.3. Modelos de procesamiento de imágenes
- 6.2. Capas convolucionales
 - 6.2.1. Reutilización de pesos en la convolución
 - 6.2.2. Convolución 2D
 - 6.2.3. Funciones de activación
- 6.3. Capas de agrupación e implementación de capas de agrupación con Keras
 - 6.3.1. *Pooling* y *Striding*
 - 6.3.2. *Flattening*
 - 6.3.3. Tipos de *Pooling*
- 6.4. Arquitecturas CNN
 - 6.4.1. Arquitectura VGG
 - 6.4.2. Arquitectura AlexNet
 - 6.4.3. Arquitectura ResNet

Módulo 7. Secuencias de procesamiento utilizando RNN (Redes Neuronales Recurrentes) y CNN (Redes Neuronales Convolucionales)

- 7.1. Neuronas y capas recurrentes
 - 7.1.1. Tipos de neuronas recurrentes
 - 7.1.2. Arquitectura de una capa recurrente
 - 7.1.3. Aplicaciones de las capas recurrentes
- 7.2. Entrenamiento de Redes Neuronales Recurrentes (RNN)
 - 7.2.1. Backpropagation a través del tiempo (BPTT)
 - 7.2.2. Gradiente descendente estocástico
 - 7.2.3. Regularización en entrenamiento de RNN
- 7.3. Evaluación de modelos RNN
 - 7.3.1. Métricas de evaluación
 - 7.3.2. Validación cruzada
 - 7.3.3. Ajuste de hiperparámetros
- 7.4. RNN preentrenados
 - 7.4.1. Redes preentrenadas
 - 7.4.2. Trasferencia de aprendizaje
 - 7.4.3. Ajuste fino
- 7.5. Pronóstico de una serie de tiempo
 - 7.5.1. Modelos estadísticos para pronósticos
 - 7.5.2. Modelos de series temporales
 - 7.5.3. Modelos basados en redes neuronales
- 7.6. Interpretación de los resultados del análisis de series temporales
 - 7.6.1. Análisis de componentes principales
 - 7.6.2. Análisis de cluster
 - 7.6.3. Análisis de correlaciones
- 7.7. Manejo de secuencias largas
 - 7.7.1. Long Short-Term Memory (LSTM)
 - 7.7.2. Gated Recurrent Units (GRU)
 - 7.7.3. Convolucionales 1D
- 7.8. Aprendizaje de secuencia parcial
 - 7.8.1. Métodos de aprendizaje profundo
 - 7.8.2. Modelos generativos
 - 7.8.3. Aprendizaje de refuerzo

- 7.9. Aplicación Práctica de RNN y CNN
 - 7.9.1. Procesamiento de lenguaje natural
 - 7.9.2. Reconocimiento de patrones
 - 7.9.3. Visión por computador
- 7.10. Diferencias en los resultados clásicos
 - 7.10.1. Métodos clásicos vs RNN
 - 7.10.2. Métodos clásicos vs CNN
 - 7.10.3. Diferencia en tiempo de entrenamiento

Módulo 8. Procesamiento del lenguaje natural (NLP) con Redes Naturales Recurrentes (RNN) y Atención

- 8.1. Generación de texto utilizando RNN
 - 8.1.1. Entrenamiento de una RNN para generación de texto
 - 8.1.2. Generación de lenguaje natural con RNN
 - 8.1.3. Aplicaciones de generación de texto con RNN
- 8.2. Creación del conjunto de datos de entrenamiento
 - 8.2.1. Preparación de los datos para el entrenamiento de una RNN
 - 8.2.2. Almacenamiento del conjunto de datos de entrenamiento
 - 8.2.3. Limpieza y transformación de los datos
- 8.3. Análisis de Sentimiento
 - 8.3.1. Clasificación de opiniones con RNN
 - 8.3.2. Detección de temas en los comentarios
 - 8.3.3. Análisis de sentimiento con algoritmos de aprendizaje profundo
- 8.4. Red de codificador-decodificador para la traducción automática neuronal
 - 8.4.1. Entrenamiento de una RNN para la traducción automática
 - 8.4.2. Uso de una red *encoder-decoder* para la traducción automática
 - 8.4.3. Mejora de la precisión de la traducción automática con RNN
- 8.5. Mecanismos de atención
 - 8.5.1. Aplicación de mecanismos de atención en RNN
 - 8.5.2. Uso de mecanismos de atención para mejorar la precisión de los modelos
 - 8.5.3. Ventajas de los mecanismos de atención en las redes neuronales

- 8.6. Modelos *Transformers*
 - 8.6.1. Uso de los modelos *Transformers* para procesamiento de lenguaje natural
 - 8.6.2. Aplicación de los modelos *Transformers* para visión
 - 8.6.3. Ventajas de los modelos *Transformers*
- 8.7. *Transformers* para visión
 - 8.7.1. Uso de los modelos *Transformers* para visión
 - 8.7.2. Preprocesamiento de los datos de imagen
 - 8.7.3. Entrenamiento de un modelo Transformer para visión
- 8.8. Librería de *Transformers* de Hugging Face
 - 8.8.1. Uso de la librería de *Transformers* de Hugging Face
 - 8.8.2. Aplicación de la librería de *Transformers* de Hugging Face
 - 8.8.3. Ventajas de la librería de *Transformers* de Hugging Face
- 8.9. Otras Librerías de *Transformers*. Comparativa
 - 8.9.1. Comparación entre las distintas librerías de *Transformers*
 - 8.9.2. Uso de las demás librerías de *Transformers*
 - 8.9.3. Ventajas de las demás librerías de *Transformers*
- 8.10. Desarrollo de una Aplicación de NLP con RNN y Atención. Aplicación Práctica
 - 8.10.1. Desarrollo de una aplicación de procesamiento de lenguaje natural con RNN y atención
 - 8.10.2. Uso de RNN, mecanismos de atención y modelos *Transformers* en la aplicación
 - 8.10.3. Evaluación de la aplicación práctica
- 9.3. Codificadores automáticos apilados
 - 9.3.1. Redes neuronales profundas
 - 9.3.2. Construcción de arquitecturas de codificación
 - 9.3.3. Uso de la regularización
- 9.4. Autocodificadores convolucionales
 - 9.4.1. Diseño de modelos convolucionales
 - 9.4.2. Entrenamiento de modelos convolucionales
 - 9.4.3. Evaluación de los resultados
- 9.5. Eliminación de ruido de codificadores automáticos
 - 9.5.1. Aplicación de filtros
 - 9.5.2. Diseño de modelos de codificación
 - 9.5.3. Uso de técnicas de regularización
- 9.6. Codificadores automáticos dispersos
 - 9.6.1. Incrementar la eficiencia de la codificación
 - 9.6.2. Minimizando el número de parámetros
 - 9.6.3. Utilización de técnicas de regularización
- 9.7. Codificadores automáticos variacionales
 - 9.7.1. Utilización de optimización variacional
 - 9.7.2. Aprendizaje profundo no supervisado
 - 9.7.3. Representaciones latentes profundas
- 9.8. Generación de imágenes MNIST de moda
 - 9.8.1. Reconocimiento de patrones
 - 9.8.2. Generación de imágenes
 - 9.8.3. Entrenamiento de redes neuronales profundas
- 9.9. Redes adversarias generativas y modelos de difusión
 - 9.9.1. Generación de contenido a partir de imágenes
 - 9.9.2. Modelado de distribuciones de datos
 - 9.9.3. Uso de redes adversarias
- 9.10. Implementación de los Modelos. Aplicación Práctica
 - 9.10.1. Implementación de los modelos
 - 9.10.2. Uso de datos reales
 - 9.10.3. Evaluación de los resultados

Módulo 9. Autoencoders, GANs, y Modelos de Difusión

- 9.1. Representaciones de datos eficientes
 - 9.1.1. Reducción de dimensionalidad
 - 9.1.2. Aprendizaje profundo
 - 9.1.3. Representaciones compactas
- 9.2. Realización de PCA con un codificador automático lineal incompleto
 - 9.2.1. Proceso de entrenamiento
 - 9.2.2. Implementación en Python
 - 9.2.3. Utilización de datos de prueba
- 9.3. Codificadores automáticos apilados
 - 9.3.1. Redes neuronales profundas
 - 9.3.2. Construcción de arquitecturas de codificación
 - 9.3.3. Uso de la regularización
- 9.4. Autocodificadores convolucionales
 - 9.4.1. Diseño de modelos convolucionales
 - 9.4.2. Entrenamiento de modelos convolucionales
 - 9.4.3. Evaluación de los resultados
- 9.5. Eliminación de ruido de codificadores automáticos
 - 9.5.1. Aplicación de filtros
 - 9.5.2. Diseño de modelos de codificación
 - 9.5.3. Uso de técnicas de regularización
- 9.6. Codificadores automáticos dispersos
 - 9.6.1. Incrementar la eficiencia de la codificación
 - 9.6.2. Minimizando el número de parámetros
 - 9.6.3. Utilización de técnicas de regularización
- 9.7. Codificadores automáticos variacionales
 - 9.7.1. Utilización de optimización variacional
 - 9.7.2. Aprendizaje profundo no supervisado
 - 9.7.3. Representaciones latentes profundas
- 9.8. Generación de imágenes MNIST de moda
 - 9.8.1. Reconocimiento de patrones
 - 9.8.2. Generación de imágenes
 - 9.8.3. Entrenamiento de redes neuronales profundas
- 9.9. Redes adversarias generativas y modelos de difusión
 - 9.9.1. Generación de contenido a partir de imágenes
 - 9.9.2. Modelado de distribuciones de datos
 - 9.9.3. Uso de redes adversarias
- 9.10. Implementación de los Modelos. Aplicación Práctica
 - 9.10.1. Implementación de los modelos
 - 9.10.2. Uso de datos reales
 - 9.10.3. Evaluación de los resultados

Módulo 10. Reinforcement Learning

- 10.1. Optimización de las recompensas y la búsqueda de políticas
 - 10.1.1. Algoritmos de optimización de recompensas
 - 10.1.2. Procesos de búsqueda de políticas
 - 10.1.3. Aprendizaje por refuerzo para optimizar las recompensas
- 10.2. OpenAI
 - 10.2.1. Entorno OpenAI Gym
 - 10.2.2. Creación de entornos OpenAI
 - 10.2.3. Algoritmos de aprendizaje por refuerzo en OpenAI
- 10.3. Políticas de redes neuronales
 - 10.3.1. Redes neuronales convolucionales para la búsqueda de políticas
 - 10.3.2. Políticas de aprendizaje profundo
 - 10.3.3. Ampliación de políticas de redes neuronales
- 10.4. Evaluación de acciones: el problema de la asignación de créditos
 - 10.4.1. Análisis de riesgo para la asignación de créditos
 - 10.4.2. Estimación de la rentabilidad de los préstamos
 - 10.4.3. Modelos de evaluación de créditos basados en redes neuronales
- 10.5. Gradientes de Política
 - 10.5.1. Aprendizaje por refuerzo con gradientes de política
 - 10.5.2. Optimización de gradientes de política
 - 10.5.3. Algoritmos de gradientes de política
- 10.6. Procesos de decisión de Markov
 - 10.6.1. Optimización de procesos de decisión de Markov
 - 10.6.2. Aprendizaje por refuerzo para procesos de decisión de Markov
 - 10.6.3. Modelos de procesos de decisión de Markov
- 10.7. Aprendizaje de diferencias temporales y *Q-Learning*
 - 10.7.1. Aplicación de diferencias temporales en el aprendizaje
 - 10.7.2. Aplicación de *Q-Learning* en el aprendizaje
 - 10.7.3. Optimización de parámetros de *Q-Learning*
- 10.8. Implementación de Deep *Q-Learning* y variantes de Deep *Q-Learning*
 - 10.8.1. Construcción de redes neuronales profundas para Deep *Q-Learning*
 - 10.8.2. Implementación de Deep *Q-Learning*
 - 10.8.3. Variaciones de Deep *Q-Learning*
- 10.9. Algoritmos de Reinforcement Learning
 - 10.9.1. Algoritmos de aprendizaje por refuerzo
 - 10.9.2. Algoritmos de aprendizaje por recompensa
 - 10.9.3. Algoritmos de aprendizaje por castigo
- 10.10. Diseño de un entorno de aprendizaje por Refuerzo. Aplicación Práctica
 - 10.10.1. Diseño de un entorno de aprendizaje por refuerzo
 - 10.10.2. Implementación de un algoritmo de aprendizaje por refuerzo
 - 10.10.3. Evaluación de un algoritmo de aprendizaje por refuerzo

“


Estudia desde la comodidad de tu hogar y actualiza tus conocimientos de forma online con TECH, la Universidad digital más grande del mundo”

06

Metodología

Este programa de capacitación ofrece una forma diferente de aprender. Nuestra metodología se desarrolla a través de un modo de aprendizaje de forma cíclica: ***el Relearning***.

Este sistema de enseñanza es utilizado, por ejemplo, en las facultades de medicina más prestigiosas del mundo y se ha considerado uno de los más eficaces por publicaciones de gran relevancia como el ***New England Journal of Medicine***.



66

Descubre el Relearning, un sistema que abandona el aprendizaje lineal convencional para llevarte a través de sistemas cílicos de enseñanza: una forma de aprender que ha demostrado su enorme eficacia, especialmente en las materias que requieren memorización"

Estudio de Caso para contextualizar todo el contenido

Nuestro programa ofrece un método revolucionario de desarrollo de habilidades y conocimientos. Nuestro objetivo es afianzar competencias en un contexto cambiante, competitivo y de alta exigencia.

“

Con TECH podrás experimentar una forma de aprender que está moviendo los cimientos de las universidades tradicionales de todo el mundo”



Accederás a un sistema de aprendizaje basado en la reiteración, con una enseñanza natural y progresiva a lo largo de todo el temario.



El alumno aprenderá, mediante actividades colaborativas y casos reales, la resolución de situaciones complejas en entornos empresariales reales.

Un método de aprendizaje innovador y diferente

El presente programa de TECH es una enseñanza intensiva, creada desde 0, que propone los retos y decisiones más exigentes en este campo, ya sea en el ámbito nacional o internacional. Gracias a esta metodología se impulsa el crecimiento personal y profesional, dando un paso decisivo para conseguir el éxito. El método del caso, técnica que sienta las bases de este contenido, garantiza que se sigue la realidad económica, social y profesional más vigente.

“

Nuestro programa te prepara para afrontar nuevos retos en entornos inciertos y lograr el éxito en tu carrera”

El método del caso ha sido el sistema de aprendizaje más utilizado por las mejores escuelas de Informática del mundo desde que éstas existen. Desarrollado en 1912 para que los estudiantes de Derecho no solo aprendiesen las leyes a base de contenidos teóricos, el método del caso consistió en presentarles situaciones complejas reales para que tomasen decisiones y emitiesen juicios de valor fundamentados sobre cómo resolverlas. En 1924 se estableció como método estándar de enseñanza en Harvard.

Ante una determinada situación, ¿qué debería hacer un profesional? Esta es la pregunta a la que te enfrentamos en el método del caso, un método de aprendizaje orientado a la acción. A lo largo del curso, los estudiantes se enfrentarán a múltiples casos reales. Deberán integrar todos sus conocimientos, investigar, argumentar y defender sus ideas y decisiones.

Relearning Methodology

TECH aúna de forma eficaz la metodología del Estudio de Caso con un sistema de aprendizaje 100% online basado en la reiteración, que combina elementos didácticos diferentes en cada lección.

Potenciamos el Estudio de Caso con el mejor método de enseñanza 100% online: el Relearning.

En 2019 obtuvimos los mejores resultados de aprendizaje de todas las universidades online en español en el mundo.

En TECH aprenderás con una metodología vanguardista concebida para capacitar a los directivos del futuro. Este método, a la vanguardia pedagógica mundial, se denomina Relearning.

Nuestra universidad es la única en habla hispana licenciada para emplear este exitoso método. En 2019, conseguimos mejorar los niveles de satisfacción global de nuestros alumnos (calidad docente, calidad de los materiales, estructura del curso, objetivos...) con respecto a los indicadores de la mejor universidad online en español.





En nuestro programa, el aprendizaje no es un proceso lineal, sino que sucede en espiral (aprender, desaprender, olvidar y reaprender). Por eso, se combinan cada uno de estos elementos de forma concéntrica. Con esta metodología se han capacitado más de 650.000 graduados universitarios con un éxito sin precedentes en ámbitos tan distintos como la bioquímica, la genética, la cirugía, el derecho internacional, las habilidades directivas, las ciencias del deporte, la filosofía, el derecho, la ingeniería, el periodismo, la historia o los mercados e instrumentos financieros. Todo ello en un entorno de alta exigencia, con un alumnado universitario de un perfil socioeconómico alto y una media de edad de 43,5 años.

El Relearning te permitirá aprender con menos esfuerzo y más rendimiento, implicándote más en tu capacitación, desarrollando el espíritu crítico, la defensa de argumentos y el contraste de opiniones: una ecuación directa al éxito.

A partir de la última evidencia científica en el ámbito de la neurociencia, no solo sabemos organizar la información, las ideas, las imágenes y los recuerdos, sino que sabemos que el lugar y el contexto donde hemos aprendido algo es fundamental para que seamos capaces de recordarlo y almacenarlo en el hipocampo, para retenerlo en nuestra memoria a largo plazo.

De esta manera, y en lo que se denomina Neurocognitive context-dependent e-learning, los diferentes elementos de nuestro programa están conectados con el contexto donde el participante desarrolla su práctica profesional.

Este programa ofrece los mejores materiales educativos, preparados a conciencia para los profesionales:



Material de estudio

Todos los contenidos didácticos son creados por los especialistas que van a impartir el curso, específicamente para él, de manera que el desarrollo didáctico sea realmente específico y concreto.

Estos contenidos son aplicados después al formato audiovisual, para crear el método de trabajo online de TECH. Todo ello, con las técnicas más novedosas que ofrecen piezas de gran calidad en todos y cada uno los materiales que se ponen a disposición del alumno.



Clases magistrales

Existe evidencia científica sobre la utilidad de la observación de terceros expertos.

El denominado Learning from an Expert afianza el conocimiento y el recuerdo, y genera seguridad en las futuras decisiones difíciles.



Prácticas de habilidades y competencias


Realizarán actividades de desarrollo de competencias y habilidades específicas en cada área temática. Prácticas y dinámicas para adquirir y desarrollar las destrezas y habilidades que un especialista precisa desarrollar en el marco de la globalización que vivimos.



Lecturas complementarias

Artículos recientes, documentos de consenso y guías internacionales, entre otros. En la biblioteca virtual de TECH el estudiante tendrá acceso a todo lo que necesita para completar su capacitación.





07

Titulación

El Máster Título Propio en Deep Learning garantiza, además de la capacitación más rigurosa y actualizada, el acceso a dos diplomas de Máster Propio, uno expedido por TECH Global University y otro expedido por la Universidad Latinoamericana y del Caribe.



66

Supera con éxito este programa y recibe tu
titulación universitaria sin desplazamientos
ni farragosos trámites”

El programa del **Máster Título Propio en Deep Learning** es el más completo del panorama académico actual. A su egreso, el estudiante recibirá un diploma universitario emitido por TECH Global University, y otro por la Universidad Latinoamericana y del Caribe.

Estos títulos de formación permanente y actualización profesional de TECH Global University y Universidad Latinoamericana y del Caribe garantizan la adquisición de competencias en el área de conocimiento, otorgando un alto valor curricular al estudiante que supere las evaluaciones y acredite el programa tras cursarlo en su totalidad.


Este doble reconocimiento, de dos destacadas instituciones universitarias, suponen una doble recompensa a una formación integral y de calidad, asegurando que el estudiante obtenga una certificación reconocida tanto a nivel nacional como internacional. Este mérito académico le posicionará como un profesional altamente capacitado y preparado para enfrentar los retos y demandas en su área profesional.

Título: **Máster Título Propio en Deep Learning**

Modalidad: **online**

Duración: **12 meses**

Acreditación: **60 ECTS**





Máster Título Propio Deep Learning

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Universidad ULAC
- » Acreditación: 60 ECTS
- » Horario: a tu ritmo
- » Exámenes: online

Máster Título Propio

Deep Learning