

PROGRAMA DE CURSO

Código	Nombre			
ME7260	Aprendizaje Profundo en Diagnóstico y Pronóstico de Fallas			
Nombre en Inglés				
Deep Learning for Fault Diagnostics and Prognostics				
SCT	Unidades Docentes	Horas de Cátedra	Horas Docencia Auxiliar	Horas de Trabajo Personal
6	10	3	0	7
Requisitos			Carácter del Curso	
			Electivo de Pre y Postgrado	
Competencia a la que tributa el curso				
<ol style="list-style-type: none"> 1. Concebir, formular y aplicar modelos computacionales de inteligencia artificial y también modelos físico-matemáticos para la resolución de problemas relacionados con detección, diagnóstico y pronóstico de daño en estructuras e equipos. 2. Interpretar los resultados de la modelación y simulación de fenómenos relacionados con los análisis de daños y fallas en Confiabilidad, Mantenibilidad y Gestión de Activos Físicos de componentes, equipos y sistemas mecánicos, estableciendo la pertinencia de las técnicas utilizada para ello. 3. Comunicar ideas y resultados de trabajos profesionales o de investigación, en forma escrita y oral, tanto en español como en inglés. 4. Trabajar en equipos multidisciplinarios, en condiciones académico industriales, asumiendo el liderazgo en las materias inherentes a su profesión en forma crítica y autocrítica. 				
Resultados de Aprendizaje				
<p>El propósito del curso es introducir a los estudiantes al área de aprendizaje profundo (Deep Learning) para el modelamiento, simulación y solución de problemas relacionados a la detección, diagnóstico y pronóstico de daño en estructuras y equipos. Las técnicas de aprendizaje profundo corresponden a los últimos avances en inteligencia artificial con aplicaciones importantes en el contexto de la evaluación del estado de salud de equipos complejos utilizando datos masivos y multidimensionales obtenidos a partir de redes de sensores instalados en los equipos. Durante el curso, los estudiantes serán expuestos a la teoría detrás de las técnicas de Deep Learning, comprenderán su funcionamiento, construcción y entrenamiento de modelos y los usos en el contexto de la gestión y pronóstico de la salud de equipos y estructuras.</p> <p>Desde el punto de vista práctico, el curso pretende que los estudiantes sean capaces de modelar y analizar problemas de detección, diagnóstico y pronóstico de daño a través del desarrollo e implementación de modelos en base a Deep Learning y utilizando señales de sensores de monitoreo de la salud de equipo y estructuras. Desde el punto de vista teórico el curso busca que los estudiantes sean capaces de leer y comprender artículos científicos que le entreguen los últimos avances en las áreas de Deep Learning y la Gestión de la Salud de Sistemas. Por lo tanto, el curso tendrá un sustancial sesgo práctico y la evaluación será en su gran parte basada en tareas de programación y evaluación del proyecto final.</p>				

Al término del curso el estudiante demuestra que puede:

- Modelar y desarrollar la solución a un problema real en la detección, diagnóstico y pronóstico de daño en base a técnicas de Deep Learning.
- Escoger y diseñar una arquitectura de Deep Learning en base al tipo, cantidad y dimensionalidad de los datos disponibles para entrenamiento.
- Implementar un modelo de Deep Learning usando TensorFlow
- Comparar distintos modelos de detección, diagnóstico y pronóstico de daño en base a Deep Learning según métricas objetivas de eficiencia y efectividad.
- Optimizar modelos de Deep Learning para la detección, diagnóstico y pronóstico de daño en estructuras y equipos.

Metodología Docente	Evaluación General
<p>La metodología consiste en clases teóricas, revisión y presentación de artículos del estado del arte, trabajos prácticos y proyecto. Asimismo, se considera un examen de medio semestre y uno final.</p> <p>El curso se desarrollará con metodología activo-participativa en donde la principal estrategia que desarrollaran es el "método proyectos".</p>	<p>La propuesta de evaluación es de proceso, en donde el estudiante deberá demostrar sus competencias en las siguientes instancias:</p> <p>Práctica:</p> <ul style="list-style-type: none"> • 5 tareas • 1 proyecto semestral <p>Teórica</p> <ul style="list-style-type: none"> • 1 Control (mid-term) • 1 Examen <p>Nota Final: 40% Teórica, 40% Práctica y 20% Participación.</p>

Unidades Temáticas

Número	Nombre de la Unidad	Duración en Semanas
1	Fundamentos	3
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
<ul style="list-style-type: none"> • Internet de las Cosas y Big Machinery Data • Aprendizaje Profundo • Redes Neuronales Profundas: <ul style="list-style-type: none"> ○ Gradient Based Learning 	<p>El estudiante:</p> <ol style="list-style-type: none"> 1. Comprende los conceptos de identificación, diagnóstico y pronóstico de daños 2. Comprende los conceptos de redes neuronales profundas 3. Implementa redes neuronales profundas en problemas de análisis del estado de salud de sistemas en TensorFlow 	<p>[1] caps. 6, 7 y 8 [2] cap. 10 y 11</p>

<ul style="list-style-type: none"> ○ Hidden Units ○ Back-Propagation ○ Regularización ○ Implementación en TensorFlow ● Aplicaciones de Redes Neuronales Profundas en el Diagnóstico de Daño ● Extracción y selección de Características: <ul style="list-style-type: none"> ○ Señales de Vibración y Emisiones Acústicas 	<ol style="list-style-type: none"> 4. Entiende algoritmos avanzados de optimización. 5. Comprende y aplica las distintas metodologías para el procesamiento y la extracción de información en señales de vibración y de emisión acústica. 6. Es capaz de proyectar, implementar y entrenar modelos en base a redes neuronales profundas para solucionar problemas de diagnóstico de daños 7. Es capaz de analizar el desempeño de redes neuronales profundas y compararlas con otros modelos en base a la extracción manual de características relacionadas a procesos de daño 	
--	--	--

Número	Nombre de la Unidad	Duración en Semanas
2	Diagnóstico de Fallas	6
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
<ul style="list-style-type: none"> ● Redes Neuronales Convolucionales (CNNs): <ul style="list-style-type: none"> ○ Motivación: Neurociencia ○ Operación de Convolución ○ Pooling ○ Arquitecturas CNN del Estado del Arte ○ Implementación en TensorFlow ○ CNN en Diagnostico de Daño (Identificación del Estado de Salud en Sistemas): <ul style="list-style-type: none"> ▪ Rodamientos, rotores 	<p>El estudiante:</p> <ol style="list-style-type: none"> 1. Comprende los conceptos de redes neuronales convolucionales, autoencoders, autoencoders variacionales y redes neuronales adversarias. 2. Implementa CNN, AE, VAE y GAN en problemas de análisis del estado de salud de sistemas en TensorFlow. 3. Capaz de proyectar, implementar y entrenar modelos en base a CNN y modelos generativos (VAE y GAN) para solucionar problemas diagnóstico de daños. 4. Capaz de optimizar y analizar modelos CNN, AE, VAE y GAN y compararlas con otros modelos de identificación y diagnóstico de daño. 5. Capaz de desarrollar modelos generativos no supervisados y semi-supervisados para el 	<p>[1] caps. 9, 14 y 20 [2] cap. 15 [3] Doersch (2016) [7] Verstraete et al. (2017) [6] Modarres et al. (2018) [8] San Martin et al. (2018)</p>



<ul style="list-style-type: none">○ CNN para la cuantificación de Daño:<ul style="list-style-type: none">▪ Cuantificación de Daño Estructural○ CNN para la Localización y Cuantificación de Daño a través la Segmentación de Imágenes● Autoencoders (AEs):<ul style="list-style-type: none">○ Under complete Autoencoders○ Sparse Autoencoders○ Denoising Autoencoders○ Stacked (Profundos) Autoencoders○ Implementación en TensorFlow○ AEs en Diagnostico de Daño (Identificación del Estado de Salud en Sistemas)● Introducción a Modelos Generativos● Autoencoders Variacionales (VAEs):<ul style="list-style-type: none">○ Introducción & Motivación○ Implementación en TensorFlow○ VAE en Clasificación (Diagnostico de Daño)● Redes Neuronales Adversarias (GANs):<ul style="list-style-type: none">○ Introducción & Motivación (Vanilla GAN)○ Base Matemática de las GANs Vanilla○ Implementación en TensorFlow	<p>procesamiento de datos masivos y multidimensionales aplicados a la detección y diagnóstico de daño.</p>	
--	--	--

<ul style="list-style-type: none"> ○ Análisis de Arquitecturas del Estado del Arte de GANs para el Diagnostico de Daño ○ Diagnóstico de Daño No-Supervisado (GAN + Clustering) ○ Diagnóstico de Daño Semi-Supervisado (GAN + Clustering) 		
---	--	--

Número	Nombre de la Unidad	Duración en Semanas
3	Pronóstico de Fallas	4
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
<ul style="list-style-type: none"> • Redes Neuronales Recurrentes para el Pronóstico de Daños y Estimación del Tiempo de Vida Remanente (RUL) en Estructuras y Equipos: <ul style="list-style-type: none"> ○ Unrolling Computational Graphs ○ Arquitecturas Básicas de RNNs ○ Estimación de Gradientes en RNNs ○ Backpropagation Through Time ○ Entrenamiento de RNNs ○ RNNs como Modelos Gráficos Direccionados ○ RNNs Profundas ○ RNNs Bidireccionales ○ Long Short-Term Memory RNNs 	<p>El estudiante:</p> <ol style="list-style-type: none"> 1. Comprende los conceptos de datos secuenciales, series temporales, y redes neuronales recurrentes. 2. Entiende los conceptos y es capaz de implementar en TensorFlow modelos en base a gated RNNs en problemas de análisis del estado de salud de sistemas. 3. Capaz de proyectar, implementar y entrenar modelos en base a RNN, LSTM, GRU y Bidireccionales para solucionar problemas de diagnóstico de daños. 4. Capaz de optimizar y analizar modelos RNN, LSTM, GRU y Bidireccionales y compararlas con otros modelos de pronóstico de daño. 	<p>[1] cap. 10 [2] cap. 14</p>

<ul style="list-style-type: none"> ○ Gated Recurrent Units ○ Implementación en TensorFlow ○ Aplicaciones de RNNs para el Pronóstico de Daño y la Predicción del Tiempo de Vida Remanente (RUL): <ul style="list-style-type: none"> ▪ Turbofans, Baterías Lithium-Ion 		
---	--	--

Número	Nombre de la Unidad	Duración en Semanas
4	Tópicos Avanzados	2
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
<p>Se elegirán uno o más tópicos representativos del estado del arte como los siguientes:</p> <ul style="list-style-type: none"> • Modelos y Arquitecturas para la Fusión de Datos en Modelos de Aprendizaje Profundo: <ul style="list-style-type: none"> ○ Arquitecturas en base a CNNs, VAEs y RNNs para la Fusión de Datos • Cuantificación de la Incertidumbre en Arquitecturas de Aprendizaje Profundo y Aplicaciones al Pronóstico de Daño y Predicción del Tiempo de Vida Remanente (RUL) • Capsule Neural Networks para el Diagnóstico y Pronóstico de Daño en Estructuras y Equipos. 	<p>En base a la literatura científica, el estudiante será capaz de comprender, interpretar e implementar técnicas en el estado del arte en Deep Learning en el contexto de la identificación, diagnóstico y pronóstico de daño en estructuras y equipos.</p> <p>Los resultados esperados son:</p> <ol style="list-style-type: none"> 1. Entender los conceptos de data fusión a partir de múltiples sensores en el monitoreo del estado de salud de estructuras y equipos 2. Capaz de seleccionar, implementar, optimizar y evaluar modelos en base a Capsule Neural Networks para el diagnóstico y pronóstico de daño 3. Comprender los conceptos de incertidumbre e implementar la cuantificación y propagación de incertidumbre en distintos tipos de arquitecturas de redes neuronales profundas 	<p>[4] Gal & Z. Ghahramani (2016) [5] Sabour, N. Frosst & G. E. Hinton (2017)</p>

Bibliografía General
<p>[1] Y. Goodfellow, Y. Bengio & A. Courville. "Deep Learning", MIT Press, 2016 (http://www.deeplearningbook.org).</p>

- [2] A. Géon. “Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems”, O’Reilly Media, 2017.
- [3] C. Doersch. “Tutorial on Variational Autoencoders”, arXiv:1606.05908v2 [stat.ML], 2016
- [4] Y. Gal & Z. Ghahramani. “Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning”, Proceedings of the 33rd International Conference on Machine Learning, New York, NY, USA, 2016.
- [5] S. Sabour, N. Frosst & G. E. Hinton. “Dynamic Routing Between Capsules”, 31st Conference on Neural Information Processing Systems (NIPS), Long Beach, CA, USA, 2017.
- [6] M. Ceena, N. Astorga, E. Lopez Droguett, V. Meruane. “Convolutional Neural Networks for Automated Damage Recognition and Damage Type Identification”, Structural Control and Health Monitoring, 2018.
- [7] D. Verstraete, A. Ferrada, E. Lopez Droguett, V. Meruane, M. Modarres. “Deep Learning Enabled Fault Diagnosis Using Time-Frequency Image Analysis of Rolling Element Bearings”, Shock and Vibration, 2017.
- [8] G. San Martin, E. Lopez Droguett, V. Meruane, M. Moura. “Deep Variational Auto-Encoders: A Promising Tool for Dimensionality Reduction and Ball Bearing Elements Fault Diagnosis”, Structural Health Monitoring, 2018.

Vigencia desde:	Primavera 2018
Elaborado por:	Enrique López Droguett
Revisado por:	