

Oferta de TFG

RESPONSABLE(S) DE TUTORIZACIÓN				TRABAJO FIN DE GRADO		DETALLE DEL TFG				
Número	DPTO	RESPONSABLE DE TUTORIZACIÓN	RESPONSABLE DE COTUTORIZACIÓN si procede	TIPOLOGÍA	TÍTULO	ESTUDIANTE	Descripción, resumen de contenidos y actividades a desarrollar en el ámbito de la Informática	Descripción, resumen de contenidos y actividades a desarrollar en el ámbito de las Matemáticas	Materias del Grado relacionadas	HARDWARE/ SOFTWARE/ BIBLIOGRAFÍA
1	ALG	Jesús García Miranda		Trabajos de profundización que sirvan de suplemento a algunas de las materias de la Titulación.	Criptografía con curvas elípticas	Yábir García Benchakhtir	<ul style="list-style-type: none"> - Estudiar e implementar algoritmos eficientes que trabajen sobre los puntos de las curvas elípticas - Estudiar los criterios para elegir unas curvas elípticas sobre otras con objetivo de usarlas en sistemas criptográficos. - Estudiar las ventajas e inconvenientes de usar un algoritmo como RSA frente a alternativas en ECC 	<ul style="list-style-type: none"> - Construcción genérica de una curva elíptica en el espacio proyectivo - Construcción de la estructura de grupo en la curva elíptica. - Estudiar las transformaciones entre curvas elípticas - Introducir las curvas elípticas sobre cuerpos finitos y resultados sobre las mismas en dichos cuerpos 	Álgebra I, Álgebra II, Álgebra III, Cálculo I, Cálculo II, Arquitectura de computadores, Teoría de Números y criptografía, Estructura de datos, Algorítmica, Seguridad y protección de sistemas informáticos, Fundamentos de la Programación	<ul style="list-style-type: none"> -Guide to Elliptic Curve Cryptography Darrel Hankerson Alfred Menezes Scott Vanstone - The Arithmetic of Elliptic Curves Joseph H. Silverman -Efficient Algorithms for Elliptic Curve Cryptosystems on Embedded Systems Adam D. Woodbury -Perspectives on Projective Geometry Jürgen Richter-Geber - RUST (https://www.rust-lang.org)
2	ALG	Manuel Bullejos Lorenzo	Pedro A. García Sánchez		Librería de grupos en python	Alberto Jesús Durán López	<p>Implementación de una librería en python que abarque la descripción de los contenidos descritos en la sección de matemáticas. Mejorar y extender la librería https://github.com/peditomelelas/Algebra-II/tree/master/Grupos/absalg-new</p> <p>Todos aquellos elementos que intervienen en la definición de grupo serán abstraídos mediante clases de python. Se podrán definir los diferentes grupos y comprobar sus propiedades mediante métodos y algoritmos que serán programados.</p> <p>Se podrán realizar operaciones a nivel de grupo como el producto directo, cálculo de subgrupos, comprobar solubilidad, etc y operaciones a nivel de elemento, como el orden, conmutador, centralizador...etc</p> <p>Estudio de alternativas como 'presentaciones' para la definición de un grupo y de algoritmos como el Algoritmo de Todd-Coxeter.</p>	<p>Estudio de los algoritmos y técnicas algebraicas más importantes de la Teoría de Grupos. Comenzando desde una introducción histórica de los principales grupos finitos (permutaciones, diédricos, cuaternios, etc) y abarcando en gran medida todas las características que rigen a cada uno de ellos.</p> <p>Se indagará en su estructura (subgrupos, retículo de subgrupos) y posibles relaciones estableciendo homomorfismos entre ellos. Uso de presentaciones de grupos y herramientas como el producto directo y semidirecto.</p> <p>Serie de composición y grupos resolubles.</p> <p>Acciones de grupo y p-grupos (T^a Cauchy y Burnside)</p> <p>Estudio de los principales teoremas (T^a Isomorfías, T^a Lagrange, T^a Sylow, etc) y sus posibles aplicaciones.</p> <p>Usando todas las técnicas y estructuras descritas se establecerá una clasificación de grupos de orden N.</p>	Álgebra I, Álgebra II, Álgebra III, Algorítmica, Lógica y Métodos Discretos	<ul style="list-style-type: none"> -Holt, D., Eick, B., O'Brien, E. (2005). Handbook of Computational Group Theory. New York: Chapman and Hall/CRC, https://doi.org/10.1201/9781420035216 - python, https://www.python.org/ - https://github.com/peditomelelas/Algebra-II/tree/master/Grupos/absalg-new - gap, https://www.gap-system.org

3	ALG	Pedro A. García Sánchez			Criptografía basada en retículos	Ángela Izquierdo García	<p>Aplicación en criptografía de los problemas de optimización en retículos.</p> <p>Se empezará por el estudio de los algoritmos existentes para la obtención del vector más corto en una retícula.</p> <p>Se estudiará cómo se puede utilizar el problema del vector más corto en la creación de criptosistemas.</p> <p>Supuestamente, los criptosistemas son resistentes a ataques con ordenadores cuánticos, se estudiará el por qué de esta característica.</p> <p>Se hará un estudio de los sistemas de encriptamiento que usan como base este problema matemático.</p>	<p>Estudio de problemas de optimización en retículos, y en particular, el estudio del problema del vector "más corto" en una retícula (que puede venir dada por una base).</p> <p>Supongamos que tenemos un subgrupo G de \mathbb{Z}^n, y tenemos una base, un sistema de generadores, o bien una base del espacio vectorial que genera, al que llamamos V. Si fijamos una norma, el problema de calcular el vector de $V \cap G$ con menor norma posible es un problema en general bastante complejo.</p> <p>Se pretende hacer un estudio de los algoritmos y resultados existentes relativos a este problema y a problemas asociados.</p>	Álgebra I. Álgebra II, Teoría de Números y Criptografía	<p>- Daniel J. Bernstein, Johannes Buchmann, Erik Dahmen, Post-Quantum Cryptography, Springer-Verlag Berlin Heidelberg.</p> <p>- Johannes Buchmann, Jintai Ding (Eds.), Post-Quantum Cryptography, Second International Workshop, PQCrypto 2008, Cincinnati, OH, USA, October 17-19, 2008</p> <p>- Nicolas Sendrier (Ed.), Post-Quantum Cryptography, Third International Workshop, PQCrypto 2010, Darmstadt, Germany, May 25-28, 2010</p>
---	-----	-------------------------	--	--	----------------------------------	-------------------------	--	---	---	--

4	AM / CCIA	Antonio M. Peralta Pereira	Fernando Berzal Galliano	Complementario de profundización / Iniciación a la investigación	Extensión de isometrías entre subconjuntos de dos esferas unidad / Mejora de imágenes basadas en técnicas de deep learning	David Cabezas Berrido	<p>En los últimos años, se ha generalizado la utilización de redes neuronales artificiales de tipo convolutivo para procesar señales de todo tipo. En el caso particular de las imágenes, interpretadas como señales bidimensionales, las redes convolutivas han demostrado ser útiles en multitud de problemas de procesamiento de imágenes y de visión artificial.</p> <p>El objetivo de este proyecto es comprobar el rendimiento de este tipo de técnicas en problemas de mejora de imágenes, como pueden ser la corrección de la iluminación de una fotografía, la mejora de su resolución o la eliminación de artefactos. Para ello, el alumno tendrá que realizar un estudio del estado del arte e implementar algunas de las técnicas que se han propuesto recientemente en la literatura científica.</p> <p>Actividades a desarrollar:</p> <ul style="list-style-type: none"> - Estudio de técnicas basadas en redes neuronales para la mejora de imágenes. - Implementación de dichas técnicas para evaluar su rendimiento experimentalmente. - Incorporación de dichas técnicas en una herramienta, aplicación móvil, bot o servicio "online" que permita su uso por parte de usuarios no expertos. 	<p>El Teorema de Mazur-Ulam afirma que toda isometría sobreyectiva entre espacios normados reales es una transformación afín. Este resultado, establecido en 1932, tiene un gran número de aplicaciones en materias ya estudiadas en el grado en Matemáticas. Es probable que los alumnos tengan alguna referencia previa al mismo. En 1972, P. Mankiewicz demostró que toda isometría sobreyectiva entre las bolas unidad cerradas de dos espacios normados reales admite una (única) extensión a una isometría lineal y sobreyectiva entre los mismos. Este resultado afirma que no es necesario tener una isometría sobreyectiva entre la totalidad de los espacios X e Y para poder identificar estos espacios normados, es suficiente con una identificación isométrica de las respectivas bolas unidad cerradas. Una de las variantes más recientes del Teorema de Mazur-Ulam se debe al matemático D. Tingley. Supongamos que $S(X)$ representa la esfera unidad de un espacio normado X. El conocido como Problema de Tingley pregunta cuando una isometría sobreyectiva de $S(X)$ a $S(Y)$ puede ser extendida a una isometría lineal real de X en Y. A pesar de que este problema permanece abierto incluso para espacios 2-dimensionales, en los últimos años se han publicado una gran cantidad de trabajos con respuestas afirmativas al problema de Tingley en espacios pertenecientes a varias clases de espacios de Banach.</p> <p>Los trabajos más recientes también consideran nuevas variaciones del problema de Tingley al considerar isometrías sobreyectivas entre dos subconjuntos propios de la esfera unidad de dos espacios normados (por ejemplo, los puntos extremos, o los operadores unitarios entre dos C^*-álgebras, o los subconjuntos de elementos positivos y de norma uno de dos C^*-álgebras o de otros tipos de espacios de operadores).</p> <p>El objetivo de este TFG es permitir que el alumno se familiarice con algunas de las respuestas positivas que esta última variante del problema de Tingley admite. Nos centraremos en el caso de las C^*-álgebras de los operadores lineales y acotados sobre un espacio de Hilbert complejo y la subálgebra formada por los operadores compactos. Curiosamente el problema permanece abierto para C^*-álgebras conmutativas y unitales, es decir, para $C(K)$ espacios. Pretendemos avanzar un poco en este último problema.</p> <p>Actividades a desarrollar:</p> <p>Reunir referencias bibliográficas y pruebas de los resultados publicadas en libros y artículos de investigación.</p> <p>Abordar de forma autónoma los resultados y sus demostraciones.</p>	<p>Cálculo I y II, Análisis Matemático I y II, Topología I, Análisis Funcional, Aprendizaje Automático, Inteligencia Artificial.</p>	<p>Matemáticas</p> <ul style="list-style-type: none"> • John B. Conway, A Course in Functional Analysis, 2nd Edition, Springer-Verlag, 1990. • G. Nagy, Isometries of spaces of normalized positive operators under the operator norm, Publ. Math. Debrecen 92 (2018), no. 1-2, 243-254. • A.M. Peralta, Characterizing projections among positive operators in the unit sphere, Adv. Oper. Theory 3 (2018), no. 3, 731-744. • A.M. Peralta, A survey on Tingley's problem for operator algebras, Acta Sci. Math. (Szeged) 84 (2018), 81-123. • A.M. Peralta, On the unit sphere of positive operators, Banach J. Math. Anal. 13 (2019), no. 1, 91-112. • X. Yang, X. Zhao, On the extension problems of isometric and nonexpansive mappings. In: Mathematics without boundaries. Edited by Themistocles M. Rassias and Panos M. Pardalos. 725-748, Springer, New York, 2014. Informática • Chen Chen, Qifeng Chen, Jia Xu, and Vladlen Koltun: Learning to see in the dark, CVPR'2018 • George Barbastathis, Aydogan Ozcan, and Guohai Situ: On the use of deep learning for computational imaging, Optica 6, 921-943 (2019) • Tim Brooks, Ben Mildenhall, Tianfan Xue, Jiawen Chen, Dillon Sharlet, Jonathan T. Barron: Unprocessing Images for Learned Raw Denoising, CVPR'2019 • Yu-Lun Liu, Wei-Sheng Lai, Ming-Hsuan Yang, Yung-Yu Chuang, Jia-Bin Huang: Learning to See Through Obstructions. CVPR'2020
---	-----------	----------------------------	--------------------------	--	---	-----------------------	---	---	--	--

5	CCIA	Fernando Berzal Galiano		Complementario de profundización / Iniciación a la investigación	Entrenamiento de redes neuronales profundas: resultados formales y algoritmos prácticos	Daniel Pozo Escalona	<p>El entrenamiento de una red neuronal se traduce en resolver un problema matemático de optimización en un espacio multidimensional. Este espacio, que puede contener millones de dimensiones, requiere disponer de técnicas de optimización adecuadas, que sean capaces de trabajar con los múltiples óptimos locales asociados al problema de la identificabilidad de un modelo (un modelo se dice identificable si un conjunto de entrenamiento lo suficientemente grande puede descartar todas menos una de las posibles configuraciones de sus parámetros). Aunque, esencialmente, las redes neuronales artificiales utilizadas en la industria son del mismo tipo que las que se utilizan en I.A. desde 1986, se ha hecho necesario desarrollar nuevas técnicas de optimización para permitir el entrenamiento de redes más grandes y profundas (esto es, con más neuronas y con más capas de neuronas).</p> <p>En este proyecto, se estudiarán los algoritmos de optimización más comunes en el aprendizaje profundo (SGD, Adam, AdaGrad, etc.), además de otros propuestos recientemente (Fromage [Bernstein20], Padam [Chen20]), y se hará un estudio comparativo de su eficacia en términos de efectividad, capacidad de generalización de las soluciones obtenidas y complejidad computacional.</p> <p>Se usarán diversos conjuntos de datos para realizar este estudio (p.ej. [Agarwal20]) y se evaluarán experimentalmente todos los algoritmos de optimización analizados previamente.</p>	<p>En primer lugar, se estudiarán las técnicas que ha proporcionado la teoría del aprendizaje estadístico para obtener cotas de generalización: aprendizaje PAC [Shalev-Shwartz14], complejidades dependientes de la distribución de las muestras [Bartlett02] y cotas basadas en la estabilidad algorítmica [Bousquet02].</p> <p>A continuación, se estudiarán los resultados, tanto positivos como negativos, aportados recientemente en lo relativo a cotas de generalización en modelos de redes neuronales profundas [Nagarajan19, Dziugaite17]. Se tratará de discernir en qué medida se entiende actualmente el fenómeno apuntado por [Zhang17]: la incapacidad de la teoría del aprendizaje clásica para explicar la capacidad de generalización de los modelos de redes neuronales profundas.</p> <p>Además, se estudiará la capacidad de representación de las clases de funciones definidas por redes neuronales [Bölcskei19, Montúfar14, Cybenko89, Hornik91, Lu17].</p>	Métodos Numéricos I y II, Modelos Matemáticos I, Análisis matemático I, Análisis funcional, Probabilidad, Aprendizaje Automático, Inteligencia Artificial, Modelos de Computación, Modelos Avanzados de Computación.	<p>- [Shalev-Shwartz14] Shalev-Shwartz, S., & Ben-David, S. (2014). Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press.</p> <p>- [Bousquet02] Bousquet, O., & Elisseeff, A. (2002). Stability and Generalization. Journal of Machine Learning Research, 2(Mar), 499–526.</p> <p>- [Bartlett02] Bartlett, P. L., & Mendelson, S. (2002). Rademacher and Gaussian Complexities: Risk Bounds and Structural Results. Journal of Machine Learning Research, 3(Nov), 463–482.</p> <p>- [Dziugaite17] Dziugaite, G. K., & Roy, D. M. (2017). Computing Nonvacuous Generalization Bounds for Deep (Stochastic) Neural Networks with Many More Parameters than Training Data. ArXiv:1703.11008 [CS]. http://arxiv.org/abs/1703.11008</p> <p>- [Nagarajan19] Nagarajan, V., & Kolter, J. Z. (2019). Uniform convergence may be unable to explain generalization in deep learning. ArXiv:1902.04742 [Cs, Stat]. http://arxiv.org/abs/1902.04742</p> <p>- [Zhang17] Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2017). Understanding deep learning requires rethinking generalization. ArXiv:1611.03530 [Cs]. http://arxiv.org/abs/1611.03530</p> <p>- [Bölcskei19] Bölcskei, H., Grohs, P., Kutyniok, G., & Petersen, P. (2019). Optimal Approximation with Sparsely Connected Deep Neural Networks. SIAM Journal on Mathematics of Data Science, 1(1), 8–45. https://doi.org/10.1137/18M118709X</p> <p>- [Montúfar14] Montúfar, G. F., Pascanu, R., Cho, K., & Bengio, Y. (2014). On the Number of Linear Regions of Deep Neural Networks. In Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, & K. Q. Weinberger (Eds.), Advances in Neural Information Processing Systems 27 (pp. 2924–2932). Curran Associates, Inc. http://papers.nips.cc/paper/5422-on-the-number-of-linear-regions-of-deep-neural-networks.pdf</p> <p>- [Cybenko89] Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. Mathematics of Control, Signals and Systems, 2(4), 303–314. https://doi.org/10.1007/BF02551274</p> <p>- [Hornik91] Hornik, K.</p>
---	------	-------------------------	--	--	--	----------------------	---	--	--	--

6	CCIA	Jorge Casillas Barranquero		Trabajos de profundización que sirvan de suplemento a algunas de las materias de la Titulación	Optimización Multiobjetivo para Aprendizaje Automático Justo	David Villar Martos	<p>El tema de la justicia en aprendizaje automático, por sus importantes implicaciones, está ganando gran relevancia tanto en la comunidad científica como en la empresarial. Se trata de diseñar algoritmos que no generen discriminación en la toma de decisiones en perjuicio de determinados grupos sociales.</p> <p>La principal contribución del TFG es una metodología que explora soluciones óptimas de aprendizaje automático y evalúa los límites de la equidad en relación con otras dimensiones de la evaluación de un modelo. Sostenemos que los algoritmos evolutivos multiobjetivos podrían utilizarse para dirigir un proceso de meta-aprendizaje para optimizar los hiperparámetros de un clasificador, consiguiendo así encontrar modelos que ofrezcan un amplio repertorio de equilibrios entre precisión y justicia. Dada la existencia de muchas medidas de equidad entre ellas contradictorias, el contexto es un marco ideal para el uso de optimización con muchos objetivos. Este enfoque es altamente novedoso en el campo del aprendizaje automático responsable.</p> <p>Concretamente, el TFG propone el diseño, desarrollo y experimentación de un algoritmo que contemple múltiples objetivos de diferentes familias de definición de justicia entre ellas contradictorias. Se implementará en Python. Se emplearán técnicas de many-objective optimization para manejar espacios de decisión de alta dimensión.</p>	Asimismo, el TFG analizará matemáticamente las medidas de justicia empleadas, la convergencia del algoritmo y las cualidades de los modelos empleados (principalmente, árboles de decisión y regresión logística).	Metodología de la Programación, Algorítmica, Aprendizaje Automático, Inteligencia de Negocio, Estadística Descriptiva e Introducción a la Probabilidad, Análisis Matemático II, Modelos Matemáticos II, Métodos Numéricos I y II, Análisis Funcional	<p>Hardware: Ordenador personal o portátil.</p> <p>Software: Intérprete de Python y sus paquetes habituales para ciencia de datos (Numpy, Scipy, Pandas, Matplotlib, scikit-learn...)</p> <p>Bibliografía:</p> <p>Valdivia, A., Sánchez-Monedero, J., & Casillas, J. (2020) How fair can we go in machine learning? Assessing the boundaries of fairness in decision trees. arXiv preprint arXiv:arXiv:2006.12399.</p> <p>Barocas, S., Hardt, M., & Narayanan, A. (2017). Fairness in machine learning. NIPS Tutorial, 1</p> <p>Barocas, S., Hardt, M., & Narayanan, A. (2018). Fairness and Machine Learning. fairmlbook.org, 2018. URL: http://www.fairmlbook.org.</p> <p>Mitchell, S., Potash, E., Barocas, S., D'Amour, A., & Lum, K. (2018). Prediction-based decisions and fairness: A catalogue of choices, assumptions, and definitions. arXiv preprint arXiv:1811.07867.</p> <p>Von Lücken, C., Barán, B., & Brizuela, C. (2014). A survey on multi-objective evolutionary algorithms for many-objective problems. Computational optimization and applications, 58(3), 707-756.</p>
7	CCIA	Manuel Gómez Olmedo	Ofelia Paula Retamero Pascual	Trabajos de profundización que sirvan de suplemento a algunas de las materias de la Titulación.	Aplicación de Redes Bayesianas a datos genéticos	Álvaro Beltrán Camacho	El tamaño de las distribuciones de probabilidad de un MGP crece de forma exponencial con el número de variables. Por esta razón, tanto en la generación de las redes bayesianas como al hacer inferencia sobre ellas, será necesario implementar-----	Las redes Bayesianas son un tipo de modelo gráfico probabilístico en el que las variables de interés son nodos de un grafo (dirigido acíclico), y los arcos indican las dependencias que existen entre ellas. Además existe otro nivel, cuantitativo, que completa la definición del problema y da valores a los posibles eventos relacionados con las variables del grafo, teniendo en cuenta sus dependencias. Cuando un grafo está completamente definido, se puede hacer inferencia sobre él y calcular así probabilidad de eventos que no quedan expresamente definidos o no han ocurrido.	Aprendizaje Automático Inteligencia Artificial Inferencia Estadística Álgebra II Estadística Descriptiva e Introducción a la Probabilidad	<ul style="list-style-type: none"> · Python/R · Lauritzen, S. L., & Spiegelhalter, D. J. (1988). Local computations with probabilities on graphical structures and their application to expert systems. · Karera, K. R. Building Probabilistic Graphical Models with Python. · Yang, N., Stingo, F. C. y Baladanyuthapani, V. (2014). Integrative Bayesian Network Analysis of Genomic Data

8	CCIA	Francisco Herrera Triguero	Francisco David Charre Luque		Optimización automática de arquitecturas de deep learning para la diagnosis de COVID-19 a partir de radiografías de tórax	Víctor Castro Serrano	<p>Uno de los desafíos más importantes de la Inteligencia Artificial en la actualidad es asistir en el campo de la Medicina para, entre otros objetivos, agilizar el diagnóstico de enfermedades. El área del deep learning engloba un conjunto de técnicas que abordan la complejidad de los datos mediante jerarquías de representaciones progresivamente más abstractas [1]. Dichas técnicas se basan en los conceptos de neurona artificial y redes neuronales, que se fundamentan en diferentes ámbitos matemáticos como el álgebra lineal y la inferencia estadística [2]. Un reto importante que presentan estas técnicas y que las diferencia de otros métodos de aprendizaje automático es la necesidad de diseñar arquitecturas de redes neuronales específicas para cada problema.</p> <p>El objetivo principal que se plantea en el ámbito de la Informática es aplicar métodos de optimización de arquitecturas de redes neuronales para obtener modelos de clasificación que faciliten el diagnóstico de la enfermedad COVID-19, utilizando radiografías de tórax de pacientes como fuente de datos.</p>	<p>Como estudio matemático a realizar, se plantea analizar los fundamentos de las técnicas de optimización que permiten encontrar una arquitectura neuronal adecuada: la optimización bayesiana basada en procesos gaussianos [3]. Asimismo, se estudiarán las mejoras que se pueden aplicar a la optimización bayesiana para adaptarla al caso de búsqueda de arquitecturas neuronales [4], como el uso de kernels definidos positivos para transformar el espacio de cálculo de distancia entre arquitecturas.</p>	<ul style="list-style-type: none"> - Inteligencia Artificial - Inteligencia de Negocio - Aprendizaje Automático - Inferencia Estadística - Geometría I - Análisis Funcional - Visión por Computador 	<p>Hardware: el grupo cuenta con clusters de GPUs que hacen posible el entrenamiento de modelos.</p> <p>Software: se partirá del uso de la biblioteca Autokeras, basada en Tensorflow/Keras.</p> <p>Bibliografía: [1] I. Arel, D. C. Rose, T. P. Karnowski. "Deep Machine Learning – A New Frontier in Artificial Intelligence Research". IEEE Computational Intelligence Magazine (2010) [2] I. Goodfellow, Y. Bengio, A. Courville. "Deep Learning". MIT Press (2016). [3] Brochu, E., Cora, V. M., & De Freitas, N. (2010). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. arXiv preprint arXiv:1012.2599. [4] Jin, H., Song, Q., & Hu, X. (2019, July). Auto-keras: An efficient neural architecture search system. In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (pp. 1946-1956).</p>
9	CCIA / ALG	Carlos Cano Gutiérrez	Antonio Lasanta Beceerra	Iniciación a la investigación	"Formulación, Diseño e Implementación de algoritmos en computación cuántica"	José Antonio Álvarez Ocete	<p>Los objetivos en el ámbito de la Informática son introducir al estudiante a la programación de ordenadores cuánticos, programar un algoritmo cuántico y estudiar la viabilidad y eficiencia de esta implementación. Para ello, se propone: 1) Estudiar paradigmas de programación de ordenadores cuánticos 2) Puertas lógicas cuánticas y circuitos cuánticos 3) Bibliotecas, simuladores y entornos de programación de ordenadores cuánticos 4) Estudio teórico de algoritmos cuánticos 5) Algoritmos de optimización combinatoria 6) Implementación de algoritmos en computadores cuánticos 7) Cálculo de la eficiencia empírica y teórica de los algoritmos</p>	<p>Los objetivos de aspectos matemáticos son: 1) Que el estudiante se familiarice con la formulación matemática de la mecánica cuántica. 2) Formalización matemática por medio de la computación cuántica: Operadores lógicos y puertas lógicas cuánticos. 3) Formulación matemática de algoritmos de optimización para computación cuántica.</p>	<p>Modelos de Computación, Algorítmica, Álgebra I y II, Geometría I y II, Análisis Funcional</p>	<p>* Quantum Computation and Quantum Information. Nielsen & Chuang. doi:10.1063/1.1428442 * IBM Quantum Experience (https://quantum-computing.ibm.com/) *Qiskit https://qiskit.org/</p>

10	EIO / CCIA	Úrsula Torres Parejo	M ^a Amparo Vila Miranda		<p>Estudio crítico de las herramientas estadísticas en las librerías para Big Data</p>	Maximino Suárez Van Gelderen	<p>En este trabajo, el ámbito de la informática y las matemáticas están estrechamente relacionados. Consiste en hacer una revisión profunda de las herramientas estadísticas presentes en las principales librerías existentes para Big Data (como Spark) acompañada de un juicio crítico.</p> <p>El estudiante deberá:</p> <p>Ofrecer una visión general del Big Data</p> <p>Familiarizarse con las aplicaciones y tecnologías Big Data</p> <p>Hacer un estudio de los componentes de una plataforma Big Data</p> <p>Realizar una síntesis de los paquetes de software y como pueden usarse en análisis estadístico de datos.</p>	<p>Desde el punto de vista de las matemáticas y la estadística el estudiante deberá:</p> <p>Hacer una búsqueda y revisión bibliográfica de las herramientas de análisis estadístico presentes en las principales librerías para Big Data.</p> <p>Profundizar en el estudio de técnicas estadísticas aplicables al Big Data: técnicas gráficas, análisis de datos unidimensional y multidimensional, regresión y otras técnicas de modelado, series temporales, técnicas de predicción, etc.</p> <p>Desarrollar un estudio crítico donde se ponga de manifiesto las carencias en las herramientas estadísticas de las librerías contempladas en el trabajo</p> <p>Identificar los principales retos y establecer propuestas de mejora</p>	<p>Estadística descriptiva e Introducción a la probabilidad, fundamentos de programación, fundamentos de bases de datos, estadística computacional, probabilidad, inferencia estadística, sistemas inteligentes</p>	<p>Anderson, A. Statistics for big data for dummies, 2015, John Wiley & Sons.</p> <p>Louridas, P. y Ebert, C. Embedded analytics and statistics for big data, IEEE Software, vol 30. 6:33-39, 2013.</p> <p>Buhlmann, P. y Van de Geer, S. Statistics for big data: A perspective. Statistics and Probability Letters, vol 136, 37-41, 2018.</p> <p>Govindaraju, V., Raghavan, V. y Rao, C. Big Data Analytics, 2015, Elsevier</p>
----	------------	----------------------	------------------------------------	--	--	------------------------------	--	--	---	---

11	EIO / LSI	M. Jesús García-Ligero Ramírez	Carlos Ureña Almagro	Trabajos complementarios de profundización que sirvan de suplemento a materia/s estudiada/s durante el Grado (yo veo esta) Trabajos bibliográficos sobre el estado actual de una temática relacionada con el Grado. Resolución de problemas en el ámbito de las ingenierías y la arquitectura.	Métodos de Monte-Carlo y desarrollo de software de síntesis de imágenes.	Antonio Gámiz Delgado	El objetivo de este trabajo es el estudio de métodos de Monte-Carlo que, en muchas ocasiones, proporcionan el único enfoque manejable para la resolución de problemas tanto de tipo determinísticos como estocásticos. Bajo el nombre de métodos de Monte-Carlo se agrupan diferentes técnicas basadas en el muestreo sistemático de variables aleatorias; por lo tanto, las estimaciones que resultan de los procedimientos de Monte-Carlo tienen errores de muestreo asociados, siendo necesario el estudio de técnicas de reducción de la varianza para evaluar la bondad de las estimaciones.	Se realizará el análisis, diseño, implementación y pruebas de software de visualización realista de escenarios y modelos 3D usando métodos de Monte-Carlo, usando como base la literatura relacionada y la base de software Open-Source disponible. Se tendrá como objetivo el desarrollo de software eficiente, robusto y portable. Se pondrá especial énfasis en las técnicas conocidas de reducción de varianza y/o ruido.	Grado en Matemáticas: Probabilidad. Inferencia Estadística. Grado en Informática: Informática Gráfica. Programación y Diseño Orientado a Objetos.	Hardware/Software: Ordenador personal equipado con GPU. Compiladores o intérpretes del lenguaje o lenguajes de programación elegidos. Bibliografía Matemáticas: 1.- J. E. Gentle, "Statistics and Computing. Random Number Generation and Monte Carlo Methods". Springer-Verlag, United States, 2005. 2.- A.C. Guidoum and K. Boukhetala (2016). Sim.DiffProc: Simulation of Diffusion Processes.R package version 3.2. http://CRAN.R-project.org/package=Sim.DiffProc 3.- C. P. Robert y G. Casella, "Monte Carlo Statistical Methods". Springer-Verlag, United States, 2004. 4.- B. D. Ripley, "Stochastic Simulation". John Wiley and Sons, New York, 2006. 5.- M. L. Rizzo, "Statistical Computing with R". Taylor & Francis Group, United States, 2007. Bibliografía Informática: 1.- Hughes, van Dam, McGuire, Sklar, Foley, Feiner, Akeley.: "Computer Graphics: Principles and Practice (3rd Edition)". ISBN-13: 978-0321399526, 1264 pages, Ed. Addison-Wesley Professional; 3 edition (July 20, 2013) http://cgpp.net 2.- Peter Shirley: "Ray-tracing in one weekend, the book series" https://raytracing.github.io/ 3.- Matt Pharr Wenzel Jakob Greg Humphreys: "Physically Based Rendering. From Theory to Implementation (3rd Edition)" eBook ISBN: 9780128007099, Hardcover ISBN: 9780128006450. https://pbrt.org (disponible gratuitamente) 4.- Art Owen: "Monte Carlo theory, methods and examples" https://statweb.stanford.edu/~owen/mc/ (disponible gratuitamente).
----	-----------	--------------------------------	----------------------	--	--	-----------------------	---	---	--	---

12	EIO / LSI	María del Carmen Segovia García	Carlos Ureña Almagro	Trabajos bibliográficos sobre el estado actual de una temática relacionada con el Grado. Resolución de problemas en el ámbito de las ingenierías y la arquitectura.	Métodos de Monte-Carlo de baja varianza para simulación numérica de iluminación global.	Emilio Hoyo Medina	Se realizará una revisión bibliográfica de los métodos de Montecarlo, en particular en lo referente a su aplicación a la síntesis de imágenes realistas. Se investigarán técnicas de reducción de la varianza para métodos de Monte-Carlo, que permitan estimaciones más eficientes. Se identificarán los principales retos y soluciones propuestas para el futuro del área.	Se realizará el análisis, diseño implementación y pruebas de software basado en algoritmos descritos en la literatura (basados en métodos de Monte-Carlo) para la simulación numérica eficiente y robusta de la propagación de radiancia en el espectro visible y la síntesis de imágenes realistas. Se analizarán posibilidades de mejora de los algoritmos descritos en robustez, eficiencia o reducción de varianza.	Grado en Matemáticas: Estadística Descriptiva e Introducción a la Probabilidad, Probabilidad, Procesos Estocásticos. Grado en Ingeniería Informática: Informática Gráfica. Programación y Diseño Orientado a Objetos.	Hardware/Software: Ordenador personal equipado con GPU. Compiladores o interpretes del lenguaje de lenguajes de programación elegidos. Bibliografía Matemáticas: 1.- Kulkarni, V. G. (1999): Modeling, Analysis, Design, and Control of Stochastic Systems. Springer-Verlag New York, Inc. 2.- A. M. Johansen, L. Evers (2007): Simulation and the Monte Carlo Methods — Lecture Notes (https://warwick.ac.uk/fac/sci/statistics/staff/academic-research/johansen/teaching/mcm-2007.pdf) 3.- Graham, C.; Talay, D. (2013): Stochastic Simulation and Monte Carlo Methods. Mathematical Foundations of Stochastic Simulation. Series: Stochastic Modelling and Applied Probability, Vol. 68. Springer. Bibliografía Informática: 1.- Hughes, van Dam, McGuire, Sklar, Foley, Feiner, Akeley.: "Computer Graphics: Principles and Practice (3rd Edition)". ISBN-13: 978-0321399526, 1264 pages, Ed. Addison-Wesley Professional; 3 edition (July 20, 2013) http://cgpp.net 2.- Peter Shirley: "Ray-tracing in one weekend, the book series" https://raytracing.github.io/ (disponible gratuitamente) 3.- Matt Pharr Wenzel Jakob Greg Humphreys: "Physically Based Rendering. From Theory to Implementation (3rd Edition)" eBook ISBN: 9780128007099, Hardcover ISBN: 9780128006450. https://pbrt.org (disponible gratuitamente)
----	-----------	---------------------------------	----------------------	--	---	--------------------	--	---	--	--

13	GT / LSI	FRANCISCO JOSÉ LÓPEZ FERNÁNDEZ	CARLOS UREÑA ALMAGRO	- Complementario de profundización. - Iniciación a la investigación	Estructuras diferenciales sobre una superficie topológica y la visualización computacional de superficies.	NORBERTO FERNÁNDEZ DE LA HIGUERA	Se desarrollará software de visualización y animación 3D de superficies, software que permita ilustrar visualmente algunos de los conceptos matemáticos del ámbito de las superficies topológicas diferenciables. Para ello, se analizarán los algoritmos relacionados descritos en la literatura y se implementarán los más adecuados a los conceptos a ilustrar. Se tendrá como objetivo el desarrollo de software eficiente, robusto y portable.	En este trabajo se tratarán algunos aspectos básicos de topología diferencial en dimensión baja. De forma más precisa, se abordará una prueba sencilla de un teorema clásico de Munkres sobre la unicidad de las estructuras diferenciables soportadas por una superficie topológica.	<p>Grado en Matemáticas: Topología I y II, Curvas y Superficies, Variedades Diferenciables.</p> <p>Grado en Ingeniería Informática: Informática Gráfica. Programación y Diseño Orientado a Objetos.</p>	<p>Hardware/Software: Ordenador personal equipado con GPU. Compiladores o intérpretes del lenguaje o lenguajes de programación elegidos.</p> <p>Bibliografía Matemáticas: 1.- Champagnerkar, A., Kumar, A., and Kumaresan, S.: "Classification of surfaces via Morse theorem". Expositiones Mathematicae, 18(1), January 2000. 2.- Hatcher, Allen: "The Kirby torus trick for surfaces". https://arxiv.org/abs/1312.3518 3.- Kirby, R. C.: "Stable Homeomorphisms and the annulus conjecture". Annals of Math. 89 (1969), 575-582. 4.- Milnor, J.: "Morse theory". Princeton University Press, Princeton, New Jersey, 1963. 5.- Munkres, James R.: "Some Applications of Triangulation Theorems". University of Michigan, 1956. 6.- Warner, F. W.: "Foundations of Differentiable Manifolds and Lie groups". Graduate Texts in Mathematics, Springer, ISBN 978-1-4757-1799-0.</p> <p>Bibliografía Informática: 1.- Hughes, van Dam, McGuire, Sklar, Foley, Feiner, Akeley.: "Computer Graphics: Principles and Practice (3rd Edition)". ISBN-13: 978-0321399526, 1264 pages, Ed. Addison-Wesley Professional; 3 edition (July 20, 2013)</p>
----	----------	--------------------------------	----------------------	---	--	----------------------------------	---	---	---	---

14	LSI	María del Mar Abad Grau	Ofelia Paula Retamero Pascual	Trabajos de profundización que sirvan de suplemento a algunas de las materias de la Titulación.	Aprendizaje Automático con datos genéticos. Aplicación a autismo.	Víctor Manuel Arroyo Martín	Los datos genéticos se presentan en grandes bases de datos, en cuyo estudio, el Aprendizaje Automático permite detectar patrones que de otro modo no sería posible. En el caso de que los datos genéticos se presenten por su cadena de ADN, la detección de una enfermedad que --	El Aprendizaje Automático combina ramas de las matemáticas como son: · Álgebra lineal: vectores, matrices, espacios vectoriales y sus transformaciones lineales... · Teoría de Probabilidades y Estadística: estadística descriptiva, espacios de probabilidad, probabilidad condicional... · Cálculo multivariante: cálculo diferencial e integral, derivadas parciales, gradiente direccional...	Aprendizaje Automático Inteligencia Artificial Inferencia Estadística Estadística Descriptiva e Introducción a la Probabilidad Geometría I	· Python/R · Abu-Mostafa, Y. S., <i>Magdom-Ismael, M. y Lin H-T.</i> (2012) , Learning From Data · Geron A., (2019), Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems · Brueggeman, L., Koomar, T. y Michaelson, J. J., (2020), Forecasting risk gene discovery in autism with machine learning and genome-scale data
15	CCIA	Fernando Berzal Galiano		Complementario de profundización / Iniciación a la investigación	CycleGAN: Modelos generativos avanzados basados en técnicas de deep learning	Ismael Sánchez Torres	En los últimos años, los modelos generativos han cautivado la atención de investigadores y científicos por conseguir que una máquina sea capaz de realizar actividades que consideraríamos creativas [Foster 2019]. Los autoencoders variacionales y las GAN (G	Matemáticamente, una CycleGAN conecta dos dominios, X e Y, mediante dos correspondencias, G y F, donde G: X->Y y F: Y->X. G y F se modelan mediante redes neuronales conocidas como autocodificadores (autoencoders) y, por tanto, como funciones continuas. La	Topología I, Análisis Matemático I, Análisis Funcional, Métodos Numéricos I & II, Álgebra I, Modelos Matemáticos I, Probabilidad. Aprendizaje Automático, Inteligencia Artificial, Visión por Computador.	[Almahairi 2018] Amjad Almahairi, Sai Rajeswar, Alessandro Sordoni, Philip Bachman, Aaron Courville: "Augmented CycleGAN: Learning Many-to-Many Mappings from Unpaired Data", ICML 2018. https://arxiv.org/abs/1802.10151 [Chu 2017] Casey Chu, Andrey Zhmogino

16	CCIA	Jorge Casillas Barranquero	Pedro González Rodas	Trabajos de profundización que sirvan de suplemento a algunas de las materias de la Titulación	Herramientas para Garantizar Justicia en Aprendizaje Automático	Daniel Bolaños Martínez	<p>El aprendizaje automático, al igual que los humanos, puede discriminar y, además, su efecto es más grave por la creencia de que una máquina no tiene prejuicios y por su alta escalabilidad, que magnifica su impacto. Las causas que hacen que el aprendizaje automático no sea justa son diversas, desde el uso de una muestra sesgada o con ejemplos contaminados, hasta la existencia de proxies.</p> <p>Existen distintas definiciones de justicia que pueden agruparse en las siguientes familias: 1) paridad demográfica, 2) cuotas igualadas, 3) paridad de tasa predictiva, 4) equidad individual, y 5) equidad contrafactual. Además, algunos de estos grupos son contradictorios entre sí, de modo que conseguir una forma de justicia implica empeorar otra. Este asunto de la justicia en aprendizaje automático, por sus importantes implicaciones, está ganando gran relevancia tanto en la comunidad científica como en la empresarial.</p> <p>El TFG se propone como reto, tras un exhaustivo estudio de la bibliografía y las herramientas existentes sobre el tema, implementar una biblioteca en Python que incluya evaluaciones de justicia de todas las familias y visualizaciones para la interpretación de resultados y modelos.</p>	<p>Asimismo, este TFG analizará matemáticamente las definiciones de diversas medidas de equidad y justicia, demostrando sus propiedades, limitaciones y posibles incompatibilidades, explorando así mismo las diferentes opciones para mejorar los resultados obtenidos mediante un proceso de aprendizaje automático en los términos planteados previamente: equidad, paridad estadística/demográfica, etc.</p> <p>Para ello se tendrá que comenzar realizando una exhaustiva revisión de las diferentes formalizaciones matemáticas del concepto de equidad/justicia en la bibliografía al respecto, analizando las ventajas e inconvenientes de cada una tanto desde el punto de vista teórico como de cara a su implementación práctica en problemas concretos de clasificación mediante aprendizaje automático sin necesidad de reentrenamiento, evitando en la medida de lo posible cualquier tipo de sesgo o trato dispar, por no contar con conjuntos de datos de entrenamiento suficientemente diversos o completos.</p> <p>Es bien sabido además que el buen comportamiento de estos modelos de predicción pueden variar significativamente respecto a cierto atributo o cualidad que sea especialmente sensible para un resultado que sea justo e igualitario socialmente, y que esta posible disparidad y falta de equidad se podría expresar en términos de las correspondientes distribuciones de probabilidad, o muestrales, de los conjuntos de datos de entrada y salida para cada uno de estos grupos de individuos potencialmente discriminados, según las variables y resultados considerados.</p>	<p>Metodología de la Programación, Algorítmica, Aprendizaje Automático, Inteligencia de Negocio, Estadística Descriptiva e Introducción a la Probabilidad, Análisis Matemático II, Modelos Matemáticos II, Métodos Numéricos I y II, Análisis Funcional.</p>	<p>Hardware: Ordenador personal o portátil.</p> <p>Software: Intérprete de Python y sus paquetes habituales para ciencia de datos (Numpy, Scipy, Pandas, Matplotlib, scikit-learn...)</p> <p>Bibliografía:</p> <p>Barocas, S., Hardt, M., & Narayanan, A. (2017). Fairness in machine learning. NIPS Tutorial, 1</p> <p>Barocas, S., Hardt, M., & Narayanan, A. (2018). Fairness and Machine Learning. fairmlbook.org, 2018. URL: http://www.fairmlbook.org.</p> <p>Mitchell, S., Potash, E., Barocas, S., D'Amour, A., & Lum, K. (2018). Prediction-based decisions and fairness: A catalogue of choices, assumptions, and definitions. arXiv preprint arXiv:1811.07867.</p> <p>Zafar, M. B., Valera, I., Gomez Rodriguez, M., & Gummadi, K. P. (2017, April). Fairness beyond disparate treatment & disparate impact: Learning classification without disparate mistreatment. In Proceedings of the 26th international conference on world wide web (pp. 1171-1180).</p> <p>Corbett-Davies, S., & Goel, S. (2018). The measure and mismeasure of fairness: A critical review of fair machine learning. arXiv preprint arXiv:1808.00023.</p> <p>Saleiro, P., Kuester, B., Hinkson, L., London, J., Stevens, A., Anisfeld, A., ... & Ghani, R. (2018). Aequitas: A bias and fairness audit toolkit. arXiv preprint arXiv:1811.05577.</p>
----	------	----------------------------	----------------------	--	---	-------------------------	---	--	--	--

17	CCIA	Juan Gómez Romero	Miguel Molina Solana	Complementario de profundización	Modelos generativos del lenguaje: aspectos teóricos y prácticos	Alberto Estepa Fernández	Los modelos predictivos del lenguaje son modelos de aprendizaje automático que permiten predecir el contexto más probable para un conjunto de términos (esto es, palabras anteriores o posteriores). Este tipo de modelos tienen gran utilidad en numerosas tareas de procesamiento de lenguaje natural, como el reconocimiento de entidades, la traducción automática o la generación automática de texto. En este trabajo se estudiarán las técnicas actuales basadas en aprendizaje profundo (deep learning) para la creación de este tipo de modelos a partir de corpus de textos y se abordará un problema de generación de lenguaje.	El entrenamiento de modelos de aprendizaje profundo (Deep Learning) se basa en la optimización de una función de pérdida, como el error cuadrático medio, aplicando gradiente descendente. Las aproximaciones más habituales emplean variantes sencillas de esta técnica, como por ejemplo el gradiente descendente estocástico, y algoritmos para agilizar la convergencia y evitar óptimos locales, como Adam o RMSProp. Sin embargo, los modelos para procesamiento de lenguaje natural actuales requieren funciones de pérdida más sofisticadas para comparar distribuciones de probabilidad, como la divergencia Kullback-Leibler. En este trabajo se estudiarán las funciones de pérdida empleadas en los modelos generativos y se analizarán sus diferencias con un ejemplo práctico.	Análisis matemático I, Análisis funcional, Estadística Multivariante, Estadística Computacional, Inteligencia Artificial, Técnicas de los sistemas inteligentes, Aprendizaje automático	[1] I. Goodfellow et al. Deep learning. The MIT Press, Cambridge, Massachusetts, 2016. [2] F. Chollet. Deep learning with Python. Manning Publications Co, Shelter Island, NY, 2018. [3] Y. Goldberg. A Primer on Neural Network Models for Natural Language Processing. Journal of Artificial Intelligence Research 57:345-420, 2016. [4] T. Iqbal, S. Qureshi. Text generation models in deep learning, Journal of King Saud University. 2020. [5] D. MacKay. Information theory, inference and learning algorithms. Cambridge University Press. 2003.
----	------	-------------------	----------------------	----------------------------------	---	--------------------------	--	--	---	--

18	CCIA / GEOM	Juan Gómez Romero	Francisco Torralbo Torralbo	Iniciación a la investigación	Aprendizaje profundo y geometría	Samuel Medina Gutiérrez	<p>El objetivo del presente trabajo es que el estudiante se familiarice con la relación existente entre la geometría diferencial y un subconjunto de métodos de aprendizaje profundo que pueden formalizarse en términos de cambios de dimensionalidad. Para ello, el alumno deberá en primer lugar introducir el concepto de variedad riemanniana y los resultados más relevantes que permiten establecer dicha relación. A continuación, analizará la relevancia de la hipótesis de variedad en aprendizaje automático y cómo se formaliza el aprendizaje mediante redes neuronales profundas en términos de homomorfismos. Finalmente, implementará una solución basada en aprendizaje de la variedad para un problema de clasificación y comparará los resultados con los que se obtiene con otros métodos.</p>	<p>Estudiar los conceptos necesarios acerca de variedades riemannianas usados en algoritmos de aprendizaje profundo. Enunciar la hipótesis de variedad y sus implicaciones teórico-prácticas.</p>	<p>Estudiar los métodos de transformación de dimensionalidad no lineales en aprendizaje automático donde se usa la hipótesis de la variedad. Desarrollar una solución que aplique un método concreto de aprendizaje profundo basado en aprendizaje de la variedad para un problema de ejemplo.</p>	<p>[1] I. Chavel. Eigenvales in Riemannian geometry, volume 115 of Pure and Applied Mathematics. Academic Press, Inc., Orlando, FL, 1984. [2] I. Chavel. Riemannian geometry, volume 98 of Cambridge Studies in Advanced Mathematics. Cambridge University Press, Cambridge, second edition, 2006. [3] F. Chollet. Deep learning with Python. Manning Publications Co, Shelter Island, NY, 2018. [4] M. do Carmo. Riemannian geometry. Mathematics: Theory & Applications. Birkhäuser Boston Inc., Boston, MA, 1992. [5] C. Fefferman, S. Mitter, and H. Narayanan. Testing the manifold hypothesis. Journal of the American Mathematical Society, 29(4):983-1049, 2016. [6] I. Goodfellow. Deep learning. The MIT Press, Cambridge, Massachusetts, 2016. [7] A. J. Izenman. Introduction to manifold learning. Wiley Interdisciplinary Reviews: Computational Statistics, 4(5):439-446, 2012. [8] N. Lei, D. An, Y. Guo, K. Su, S. Liu, Z. Luo, S.-T. Yau, and X. Gu. A Geometric Understanding of Deep Learning. Engineering, 6(3):361-374, mar 2020. [9] T. Lin and H. Zha. Riemannian manifold learning. IEEE Transactions on Pattern Analysis and Machine Intelligence, 30(5):796-809, 2008.</p>
----	-------------	-------------------	-----------------------------	-------------------------------	----------------------------------	-------------------------	---	---	--	---

19	CCIA	Nicolás Marín Ruiz	Daniel Sánchez Fernández	Trabajos experimentales en el ámbito de la titulación	Extracción de descripciones en Data2Text	Carmen Vilchez Solís	El objetivo en el ámbito de la Informática es desarrollar un algoritmo de extracción de descripciones de interés en forma de un recubrimiento del conjunto de objetos, utilizando diversas formulaciones matemáticas del concepto de interés en forma de medidas definidas sobre los recubrimientos obtenidos. Se desarrollará un prototipo de prueba de concepto que permita utilizar el citado algoritmo en un dominio de aplicación.	En el ámbito de estudio denominado Data2Text se pretende generar descripciones lingüísticas de aspectos de interés (en algún sentido) de un conjunto de datos descrito mediante objetos y sus propiedades (contexto). La fase de extracción pretende obtener una representación matemática de la semántica de dichas descripciones. Existen diversos marcos matemáticos formales para hacer esto. El objetivo en el ámbito de las matemáticas es doble: por un lado, analizar y estudiar dichos marcos formales; por otro, a la vista de dicho estudio, proponer algunas medidas sobre recubrimientos para definir la "calidad" de los mismos como representación de descripciones de interés de un conjunto de objetos. Se prestará atención a las propiedades matemáticas que permiten determinar la referabilidad de conjuntos de objetos, es decir, cuándo son útiles como parte de un recubrimiento destinado a describir el conjunto completo de objetos. También se estudiarán medidas para valorar distintos aspectos de los conjuntos referenciados. Estas medidas serán la base para el desarrollo de algoritmos eficientes de extracción de descripciones.	Inteligencia Artificial. Lógica y Métodos Discretos. Metodología de la Programación.	Hardware: ordenador personal. Software: entorno de programación. Bibliografía: libros y artículos científicos sobre Análisis Formal de Conceptos y Sistemas Data2Text.
20	CCIA	Nicolás Marín Ruiz	Daniel Sánchez Fernández	Trabajos experimentales en el ámbito de la titulación	Estudio experimental de algoritmos de cálculo de retículos en Análisis Formal de Conceptos	Miguel Ángel Cantarero López	Existen en la actualidad distintos algoritmos para el cálculo de retículos de conceptos formales en el ámbito de la teoría matemática del Análisis Formal de Conceptos (Formal Concept Analysis). El objetivo en el ámbito de la Informática es implementar las distintas propuestas en una misma plataforma y desarrollar distintos experimentos para hacer una comparación justa y fiable de la eficacia y eficiencia de las distintas propuestas para contextos formales de entrada de distintas características. Un estudio de este tipo no existe en la literatura hasta donde nuestro conocimiento alcanza.	El objetivo en el ámbito de las matemáticas es estudiar la teoría matemática de Análisis Formal de Conceptos (Formal Concept Analysis), junto con las distintas propuestas algorítmicas para el cálculo de retículos de conceptos formales. De forma específica, se estudiarán las propiedades y resultados teóricos en los que se basan las distintas propuestas, así como los casos en los que dichas propuestas y heurísticas resultan más favorables para el desarrollo de algoritmos eficientes.	Metodología de la Programación. Algorítmica. Sistemas Concurrentes y Distribuidos. Inteligencia Artificial. Estadística descriptiva e Introducción a la Probabilidad. Lógica y Métodos Discretos. Álgebra 1. Álgebra 2.	Hardware: ordenador personal. Software: entorno de programación. Bibliografía: libros y artículos científicos sobre Análisis Formal de Conceptos y las distintas propuestas algorítmicas de cálculo del retículo de conceptos formales.

21	CCIA	Nicolás Marín Ruiz	Daniel Sánchez Fernández	Resolución de problemas específicos	Consulta flexible en bases de datos mediante representaciones por niveles	Patricia Córdoba Hidalgo	El objetivo en el ámbito de la Informática es desarrollar un prototipo de sistema con algunas funcionalidades de consulta flexible sobre la base de un SGBD existente, utilizando resultados fruto del estudio relativo a la parte matemática de este TFG.	Existen en la actualidad distintas implementaciones de lenguajes para consulta flexible en bases de datos, basadas en la teoría de conjuntos difusos. La consulta flexible en BD mediante conjuntos difusos plantea dos grandes problemas: en primer lugar, los distintos operadores lógicos y de agregación en las consultas pueden definirse de múltiples formas. En segundo lugar, y más importante, no es posible conservar la estructura de álgebra de Boole de las operaciones de conjunto en las operaciones sobre tablas. El objetivo en el ámbito de las matemáticas es formular distintos operadores lógicos y de agregación para dar soporte a consulta flexible mediante la teoría de representaciones por niveles, y demostrar que 1) los operadores tienen una única formulación, y 2) se conservan las propiedades Booleanas de las operaciones de conjunto. Ningún lenguaje de consulta flexible basado en conjuntos difusos puede garantizar estas propiedades.	Fundamentos de Bases de Datos. Lógica y métodos discretos. Metodología de la Programación. Fundamentos de Ingeniería del Software. Diseño y Desarrollo de Sistemas de Información.	Hardware: ordenador personal. Software: SGBD y entorno de programación. Bibliografía: artículos científicos sobre consulta flexible en bases de datos y sobre la teoría de representaciones por niveles y teoría de conjuntos difusos.
22	CCIA	Nicolás Pérez de la Blanca Capilla		Trabajos de profundización que sirvan de suplemento a algunas de las materias de la Titulación.	Estudio de la Información Mútua en Aprendizaje No Supervisado	Francisco Javier Saez Maldonado	Este TFG estudiará la medida de Información Mutua entre variables aleatorias, sus posibles implementaciones eficientes y sus repercusiones en el aprendizaje no supervisado de características desacopladas con distintos niveles de información que simplifiquen los procesos de predicción (clasificación y regresión)	Este TFG estudiará la propiedades teoricas de la medida de Información Mutua como mecanismo de identificación y caracterización de dependencias no lineales. Así mismo revisará el uso de las mismas en el problemad we aprendizaje no supervisado.	Aprendizaje Automatico. Visión por computador. Probabilidad. Inferecna Estadística	https://arxiv.org/abs/1808.06670 . http://mlg.eng.cam.ac.uk/zoubin/course03 , https://papers.nips.cc/paper/7453-entropy-and-mutual-information-in-models-of-deep-neural-networks.-pdf . https://loewex.github.io/Thesis_SindyLoewe_GredyInfoMax.pdf

23	CCIA	Salvador García López		Complementario de profundización / Iniciación a la investigación	Diseño e implementación de mapas autoorganizados (SOM) para problemas complejos de agrupamiento con restricciones	Sergio Cabezas González de Lara	<p>La integración de restricciones a nivel de instancia en los mapas auto-organizados es un campo muy inexplorado dentro del aprendizaje semi supervisado. Combina el clustering con restricciones y el SOM clásico.</p> <p>El alumno debe estudiar y comprender los conceptos básicos sobre redes neuronales, concretamente sobre los modelos no supervisados (SOM), así como la literatura existente en clustering con restricciones a nivel de instancia.</p> <p>El trabajo consistirá en implementar el modelo básico de SOM, el modelo existente que integra las restricciones en el mismo (consultar referencias) y desarrollar un nuevo esquema de integración de restricciones en SOM. Se llevarán a cabo experimentos comparativos para los tres modelos y se analizarán los resultados.</p>	<p>El alumno debe comprender el marco matemático que define los mapas auto-organizados (SOM) y el clustering con restricciones.</p> <p>El objetivo principal es desarrollar el formalismo matemático que permita integrar de forma eficaz las restricciones dentro del formalismo del SOM, comparándolo con el ya existente.</p>	<p>- Geometría II (Primer Curso, Segundo Semestre). - Análisis Matemático I (Segundo Curso, Primer Semestre). - Probabilidad (Tercer Curso, Primer Semestre). - Inferencia Estadística (Cuarto Curso, Primer Semestre). - Aprendizaje Automático (Tercer Curso, Segundo Semestre). - Técnicas de Sistemas Inteligentes (Tercer Curso, Segundo Semestre). - Metaheurísticas (Tercer Curso, Segundo Semestre). - Inteligencia Artificial (Segundo Curso, Segundo Semestre).</p>	<p>Hardware: el alumno debe realizar experimentación pesada, por lo que se recomienda que disponga de un ordenador con hardware razonablemente actualizado.</p> <p>Software: la implementación de la propuesta se llevará a cabo en el lenguaje Python. Para el análisis de resultados se recomienda tener conocimientos de R.</p> <p>Bibliografía sobre SOM: "Constraint Selection for Semi-supervised Topological Clustering"; "R. S. Michalski, J. G. Carbonell, and T. M. Mitchell, Machine Learning: An Artificial Intelligence Approach. Springer Publishing Company, Incorporated, 2013"; "T. Kohonen, "Self-organized formation of topologically correct feature maps", Biological cybernetics, vol. 43, no. 1, pp. 59–69, 1982."; "The self-organizing map", Proceedings of the IEEE, vol. 78, no. 9, pp. 1464–1480, 1990."; "T. Kohonen, M. R. Schroeder, and T. S. Huang, Eds., Self-Organizing Maps, 3rd. Berlin, Heidelberg: Springer-Verlag, 2001"</p> <p>Bibliografía sobre clustering: "B. S. Everitt, S. Landau, M. Leese, Cluster Analysis, 4th Edition, Wiley Publishing, 2009."; "O. Chapelle, B. Schikopf, A. Zien, Semi-Supervised Learning, 1st Edition, The MIT Press, 2010."; "K. Wagstaff, C. Cardie, S. Rogers, S. Schrödl, Constrained k-means clustering with background knowledge, in: Proceedings of the Eighteenth International Conference on Machine Learning, Morgan Kaufmann Publishers Inc., 2001, pp. 577–584."; "I. Davidson, S. Basu, A survey of clustering with instance level constraints, ACM Transactions on Knowledge Discovery from data 1 (2007) 1–41."</p>
----	------	-----------------------	--	--	---	---------------------------------	---	--	---	---

24	CCIA	Serafín Moral Callejón		Complementario de profundización / Iniciación a la investigación	Complejidad Algorítmica de Resolución Aproximada de Problemas de Optimización	Alberto Luque Infante	Se construirá una librería para la resolución de problemas de optimización aproximada en Python y se harán pruebas para los distintos algoritmos. Estará centrada fundamentalmente en problemas de grafos, como el mínimo cubrimiento por vértices, el conjunto independiente o el corte máximo.	El trabajo consistirá en un estudio de las clases de complejidad para la resolución aproximada de problemas de optimización, en concreto las clases NPO, APX, PTAS, FPTAS, así como de los problemas completos para dichas clases.	Modelos avanzados de computación, probabilidad y estadística, algorítmica, modelos matemáticos.	Sólo se necesita Python. Bibliografía básica: Ausiello, Giorgio, et al. Complexity and approximation: Combinatorial optimization problems and their approximability properties. Springer Science & Business Media, 2012.
25	ATC / MA	Julio Ortega Lopera	Lidia Fernández Rodríguez		Algoritmos Coevolutivos. Análisis teórico y práctico de su convergencia en arquitecturas distribuidas.	Alejandro Alonso Membrilla	<p>Los algoritmos evolutivos han demostrado ser uno de los métodos de optimización más útiles en multitud de problemas complejos. El modelo coevolutivo constituye una aproximación que puede ser eficaz para afrontar este tipo de problemas cuando el espacio de soluciones consta de un gran número de dimensiones, distribuyendo dicho espacio en una arquitectura paralela donde cada nodo busca la mejor solución avanzando dentro de su propio subespacio.</p> <p>El objetivo del alumno será estudiar este tipo de modelos evolutivos aplicados a arquitecturas distribuidas, desde sus características hasta sus aplicaciones prácticas, pasando por aquellos aspectos que puedan afectar a su eficacia y rendimiento.</p>	<p>Los algoritmos evolutivos son métodos de optimización adaptables a un gran número de problemas. Su generalidad y el bajo número de restricciones que estos algoritmos imponen al espacio de búsqueda hace que sea difícil acotar su error o garantizar su buen comportamiento.</p> <p>El alumno expondrá un modelo matemático para trabajar con los algoritmos coevolutivos implementados en computadores con paralelismo híbrido y tratará de encontrar condiciones relativas a la distribución de los subespacios de búsqueda y a la coordinación entre las distintas especies que favorezcan la convergencia de las soluciones hacia el óptimo global.</p>	Arquitectura de Computadores, Metaheurísticas, Computación de Altas Prestaciones, Probabilidad, Modelos Matemáticos	<p>HARDWARE: Servidores paralelos con nodos incluyendo procesadores superescalares y GPUs.</p> <p>BIBLIOGRAFÍA: R. Subbu and A. C. Sanderson, "Modeling and convergence analysis of distributed coevolutionary algorithms", IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS, VOL. 34, NO. 2, APRIL 2004</p> <p>R. Subbu and A. C. Sanderson, "Network-Based Distributed Planning Using Coevolutionary Agents: Architecture and Evaluation", IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART A: SYSTEMS AND HUMANS, VOL. 34, NO. 2, MARCH 2004</p>