



Línea de Trabajo fin de Máster 2025-2026

Máster Universitario en Estadística Aplicada.	
Título	Fiabilidad y calibración de modelos <i>Deep Learning</i> y su aplicación al procesamiento del lenguaje natural
Tipo	INVESTIGACIÓN ☐ ORIENTACIÓN PRÁCTICA ☒
Número de alumnos admitidos	Blanca Pulido Fernández
Profesor(es)/ email	Yolanda Román Montoya (yroman@ugr.es)
Descripción	El TFM abordará uno de los principales desafíos de la IA actual: la sobreconfianza de los modelos de Deep learning, analizando la tarea de desambiguación referencial en el campo del procesamiento del lenguaje natural (PLN). El objetivo final es crear sistemas más robustos y transparentes que sean conscientes de su propia incertidumbre; un aspecto esencial para aplicaciones en sectores críticos como la medicina o el derecho.
Objetivos particulares	Conocer diversas metodologías de trabajo Desarrollar labores de investigación Realizar una completa revisión bibliográfica de problemas actuales Adquirir capacidades para dar solución a situaciones reales
Prerrequisitos y recomendaciones	Se recomienda estar matriculado en el curso Entornos de Computación Estadística del máster en Estadística Aplicada
Plan de trabajo	Comparar modelos que utilizan estimación de incertidumbre (Bayesianos Aproximados, como MC Dropout) frente a modelos con calibración estadística (Temperature Scaling). b) Evaluar la calidad estadística de las predicciones mediante métricas avanzadas (ECE, Brier Score) y el impacto del rechazo por incertidumbre. Se utilizará como base de datos <i>WinoGrande</i>, un conjunto de 44.000 ejemplos diseñado para evaluar el razonamiento y evitar atajos superficiales en la resolución de ambigüedad. La implementación se llevará a cabo en Python, dadas las librerías especializadas que se requieren.
Competencias generales y específicas	CB: 6, 7, 8, 9, 10 CG: 1, 2, 3, 6, 9 CE: 10, 13, 15, 16, 17, 18, 19, 20, 22, 23, 26, 28, 29
Bibliografía	Blundell, C., Cornebise, J., Kavukcuoglu, K. y Wierstra, D. (2015). Weight uncertainty in neural networks. Proceedings of the 32nd International Conference on Machine Learning (ICML).

2. Brier, G. W. (1950). Verification of forecasts expressed in terms of probability. Monthly Weather Review.
3. Devlin, J., Chang, M.-W., Lee, K. y Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. NAACL-HLT.
4. Gal, Y. y Ghahramani, Z. (2016). Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. ICML.
5. Geifman, Y. y El-Yaniv, R. (2017). Selective Classification for Deep Neural Networks. NeurIPS.
6. Guo, C., Pleiss, G., Sun, Y. y Weinberger, K. Q. (2017). On Calibration of Modern Neural Networks. ICML.
7. He, P., Liu, X., Gao, J. y Chen, W. (2021). DeBERTa: Decoding-enhanced BERT with Disentangled Attention. ICLR.
8. Levesque, H., Davis, E. y Morgenstern, L. (2011). The Winograd Schema Challenge. AAAI Spring Symposium.
9. Liu, Y., Ott, M., Goyal, N., et al. (2019). RoBERTa: A Robustly Optimized BERT Pretraining Approach. arXiv:1907.11692.
10. Sakaguchi, K., Bras, R. L., Bhagavatula, C. y Choi, Y. (2020). WinoGrande: An Adversarial Winograd Schema Challenge at Scale. AAAI.
11. Soon, W. M., Ng, H. T. y Lim, D. C. Y. (2001). A Machine Learning Approach to Coreference Resolution of Noun Phrases. Computational Linguistics.
12. Wolf, T., Debut, L., Sanh, V. et al. (2020). Transformers: State-of-the-Art Natural Language Processing. EMNLP