



Mondragon
Unibertsitatea

Enpresagintza
Fakultatea

Aplicación de técnicas de Deep Learning (DL) para la detección temprana de fuga



**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea

Antecedentes y objetivos

1.1

Marketing Mix

Marketing Mix

¿Qué es?

Conjunto de modelos que sirven para tomar una o más decisiones de marketing

¿Qué engloba?



Price



Product



Promotion



Place

(McCharty, 1964)



Marketing Mix

¿Qué es?

Conjunto de modelos que sirven para tomar una o más decisiones de marketing

¿Qué engloba?



Price



Product



Promotion



Place



Physical
evidence



Process



People

(Booms & Bitner, 1981)



Marketing Mix

Tecnología y marketing (Capon & Glazer, 1987)


- Lleva tiempo siendo analizado
- Varias perspectivas diferentes
- Puede llegar a ser un factor central a la hora de determinar una estrategia de marketing

Ciencia y marketing (Bass & Weitz, 1993)

- **Objetivo:** pasar a tener una gestión centrada en el cliente



Digitalización (Reinartz et al., 2019)

- La transformación digital ha llegado a afectar a todos los puntos de la toma de decisiones de los consumidores





Marketing Mix

Personalización (Chen & Iyer, 2002)

-  Derivada de la recopilación de datos
-  Almacenamiento en bases de datos específicas

Big Data (M.-H. Huang & Rust, 2020)

-  Recopilación masiva de datos
-  Mayor uso de técnicas de big data en el contexto del marketing



1.2

Inteligencia Artificial

Inteligencia Artificial

Tecnologías de aprendizaje automático

Herramientas de aprendizaje automático

Algoritmos de aprendizaje automático

Fuentes



Aprendizaje supervisado

Aprendizaje no supervisado

Aprendizaje por refuerzo

KNN, NM, SVM, NN, RF, XGBoost, Gradient boosted, DT, CNN, NN, Regresión...

LDA, PCA, Clustering, k-mean...+

Q-learning, Multi-armed bandit, Cellular automata learning...

Algoritmos de aprendizaje en marketing

- Recomendación
- Gestión de marcas
- Predicción de decisión de compra

- Gestión de anuncios
- Predicción de demanda
- Chatbots

- Predicción de fuga
- Targeting predicto
- Retención
- Detección facial

Inteligencia Artificial

- Mayoría de las soluciones presentes en el estado del arte están basadas en la aplicación de técnicas de aprendizaje automático o en redes neuronales profundas
- Se ha detectado la posibilidad de investigación en torno a la aplicación de métodos de aprendizaje profundo




1.3

Objetivos de investigación


Objetivos de investigación

Objetivos de investigación 1: Proponer una nueva técnica de aprendizaje para la detección temprana de fuga en contextos de en los que se interacciona de manera transaccional con los clientes.



Objetivos de investigación

- Objetivos de investigación 1:** Proponer una nueva técnica de aprendizaje para la detección temprana de fuga en contextos de en los que se interacciona de manera transaccional con los clientes.
- Objetivos de investigación 2:** Proponer nuevas técnicas de DL para la detección temprana de fuga en contextos de en los que se interacciona de manera transaccional con los clientes.





**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea

Marco científico y preguntas de investigación

3.1

**Fuga de
clientes y su
impacto en el
negocio**

Fuga de clientes y su impacto

Definición (Kamakura et al., 2005)


- Tendencia de los clientes a abandonar o dejar de hacer negocios con una empresa

Impacto (Gupta et al., 2004)

- Un 1% de mejora en la retención puede incrementar en valor de una firma en un 5%

Digitalización (Lam et al., 2004)

- El retorno de la inversión neto (ROI) para las estrategias de retención suelen ser superiores a las de adquisición
- muchas compañías han comenzado a dirigir sus recursos en materia de marketing a la retención de clientes



3.2

**Aprendizaje
automático y
la fuga de
clientes**

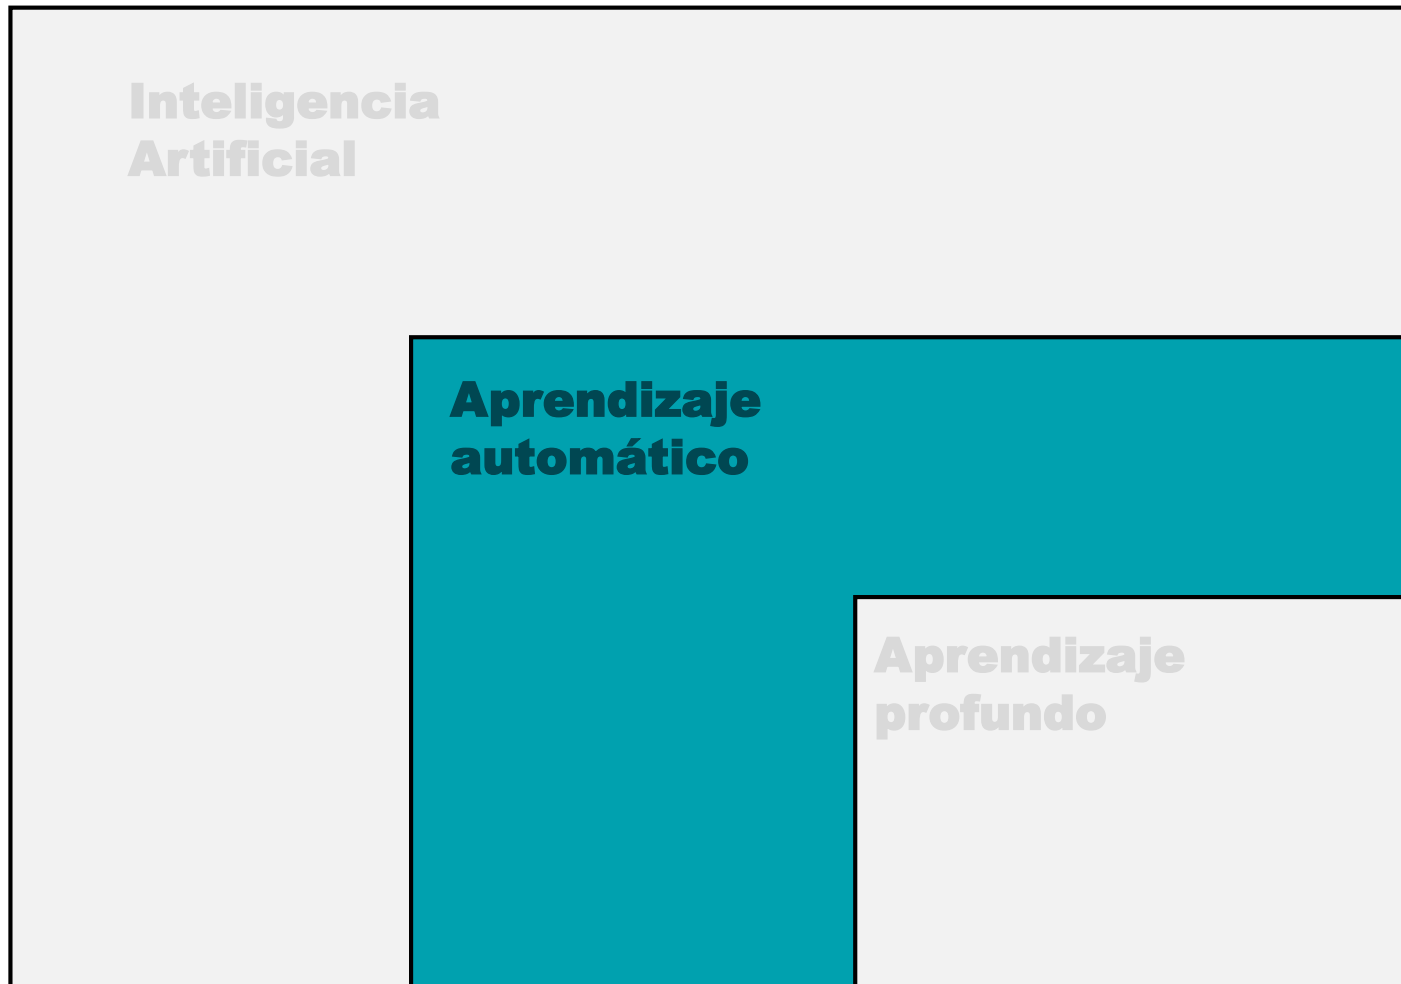
Aprendizaje automático y la fuga de clientes

Inteligencia Artificial

Aprendizaje automático



Aprendizaje profundo

Aprendizaje automático y la fuga de clientes



Aprendizaje automático y la fuga de clientes

Posibilidades (Haines et al., 1970)

-  Necesario asumir que el comportamiento de compra es un comportamiento racional dentro de los límites cognitivos y las capacidades de aprendizaje del ser humano
-  Si el patrón de compra tiende a ser sistemático, este puede ser observado y analizado siguiendo ciertos estándares



Aprendizaje automático y la fuga de clientes

Interpretación vs predicción (Hastie Trevor et al., 2001)

- Costumbre de trabajar con modelos paramétricos fáciles de interpretar



!!! la fuga es un evento complejo y puntual

Necesidad de aplicar nuevos enfoques de soluciones de minería de datos, aprendizaje automático o aprendizaje profundo



Aprendizaje automático y la fuga de clientes

C **Viabilidad** (Burez & Van den Poel, 2007; Coussement & Van den Poel, 2008; Neslin et al., 2006)

C **Aplicación demostrada**

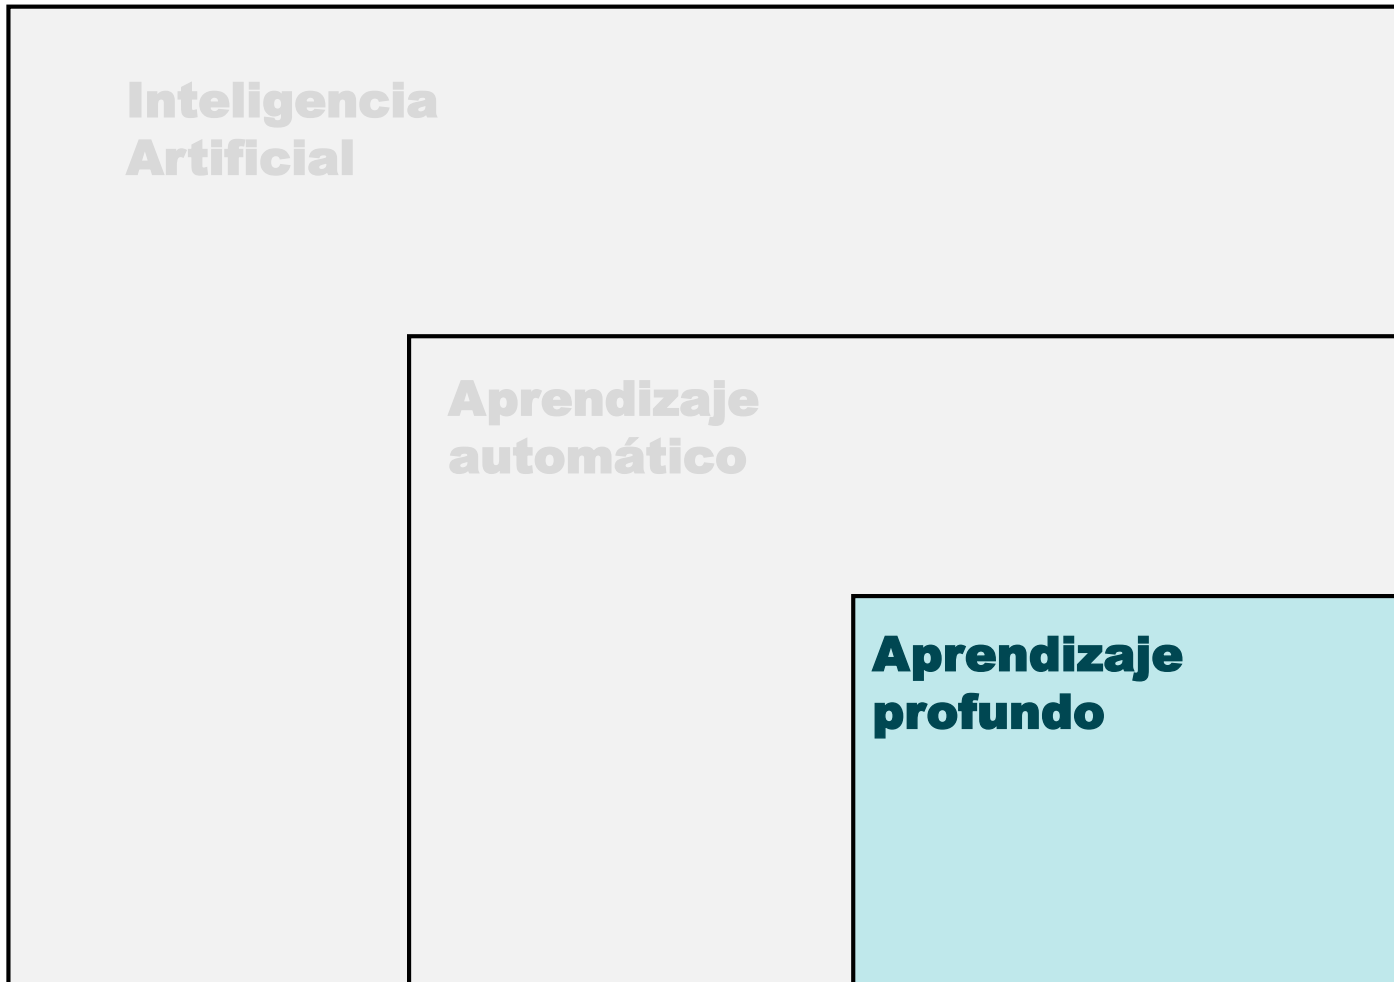
- C** Técnicas de ensamblado en el sector de las telecomunicaciones (Lemmens et al., 2007.)
- C** Aplicación de algoritmos de aprendizaje profundo combinados (Wang et al., 2024)



3.2.1

Aprendizaje Profundo

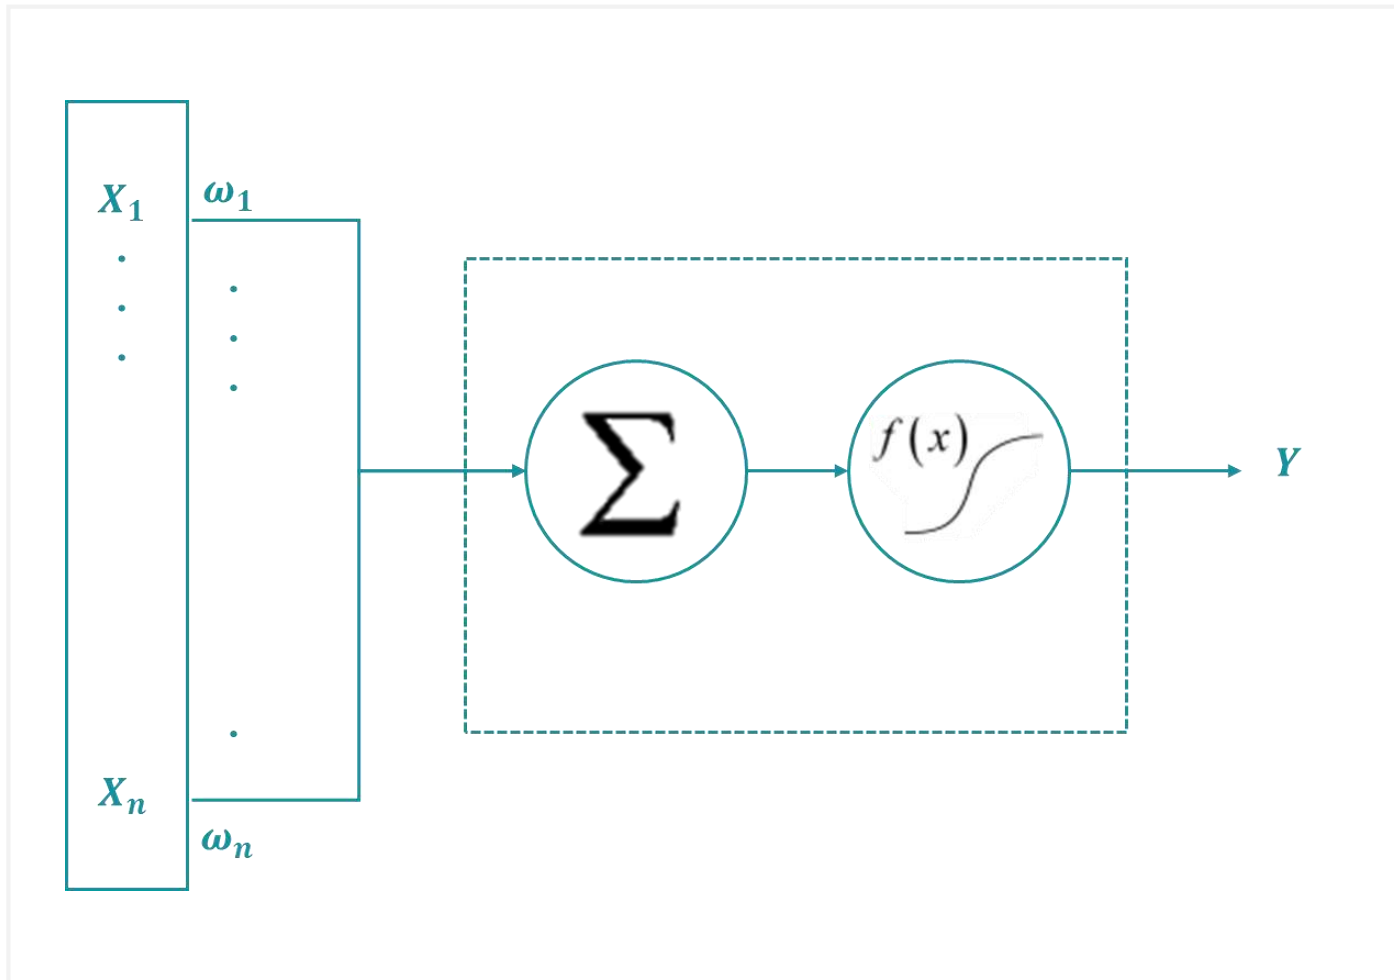
Aprendizaje Profundo



¿Qué son?

- Subconjunto de técnicas del aprendizaje automático que tratan de construir modelos jerárquicos profundos que permitan a las máquinas aprender a partir de datos en crudo. (LeCun et al., 2015)
- Cada vez más común en la mayoría de las industrias. (LeCun et al., 2015)
- Se pueden encontrar aplicaciones variadas de aplicaciones de algoritmos:
 - Mantenimiento predictivo (Li et al., 2024)
 - Encriptación de mensajes (Rohhila & Singh, 2024)
 - Procesamiento del lenguaje natural y predicción del estado de ánimo (Gadzama et al., 2024)

Aprendizaje Profundo




¿Qué son?

- Evolución de las redes neuronales, algoritmos inspirados en la estructura biológica de las neuronas introducidas. (McCulloch & Pitts, 1943).
- Cada vez más aprovechadas según la capacidad computacional del hardware aumentaba. (Basheer & Hajmeer, 2000)

Aprendizaje Profundo

C Tres arquitecturas (Deng, 2012)


- C Generativas:** tratan de caracterizar las propiedades correlativas de los datos observables para analizar patrones o caracterizar los datos
- C Discriminativas:** capacidad de clasificación de patrones, caracterizando las distribuciones de los datos no observados a partir de los datos observables
- C Híbridas:** objetivos discriminativos estando asistidas por soluciones generativas



Aprendizaje Profundo

Redes Neuronales recurrentes


- Dentro de la familia de las redes de arquitectura discriminativa
- Diseñadas específicamente para datos secuenciales o series temporales (Graves et al., 2006).
- Tienen neuronas la capacidad de tener memoria
- Permiten trabajar con series temporales multivariantes teniendo en cuenta no solo cada serie por separado sino la inter-correlación entre ellas (Weerakody et al., 2021)



Aprendizaje Profundo



Autoencoders

- La principal función de este tipo de arquitecturas es la de reducir la dimensionalidad de los datos de entrada (Hinton & Salakhutdinov, 2006)
- También suelen usarse para la detección de anomalías o la eliminación de ruido entre otros (Vincent et al., 2010).
- Suelen tener, como mínimo, una capa de entrada y una capa de salida con la misma dimensionalidad y una capa oculta con un número menor de neuronas
- En caso de tener más de una capa oculta estaríamos hablando de *autoencoders* profundos (Deng, 2012).



Aprendizaje Profundo

En conclusión

-  Los *autoencoder* deberían ser capaces de reducir la dimensionalidad de la cantidad de datos generador por la interacción de los clientes
-  Las RNN deberían permitir que las soluciones desarrolladas tengan en cuenta la temporalidad y la evolución de la relación de




3.3

Preguntas de investigación

Preguntas de investigación


Pregunta de investigación 1 ¿Es posible combinar técnicas de aprendizaje no supervisado para la detección de fuga de clientes?



Preguntas de investigación

Pregunta de investigación 1: ¿Es posible combinar técnicas de aprendizaje no supervisado para la detección de fuga de clientes?

Pregunta de investigación 2: ¿Es posible combinar el componente temporal de las RNN con la capacidad de síntesis de los autoencoder para mejorar las predicciones en series temporales irregulares?





**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea

Metodología

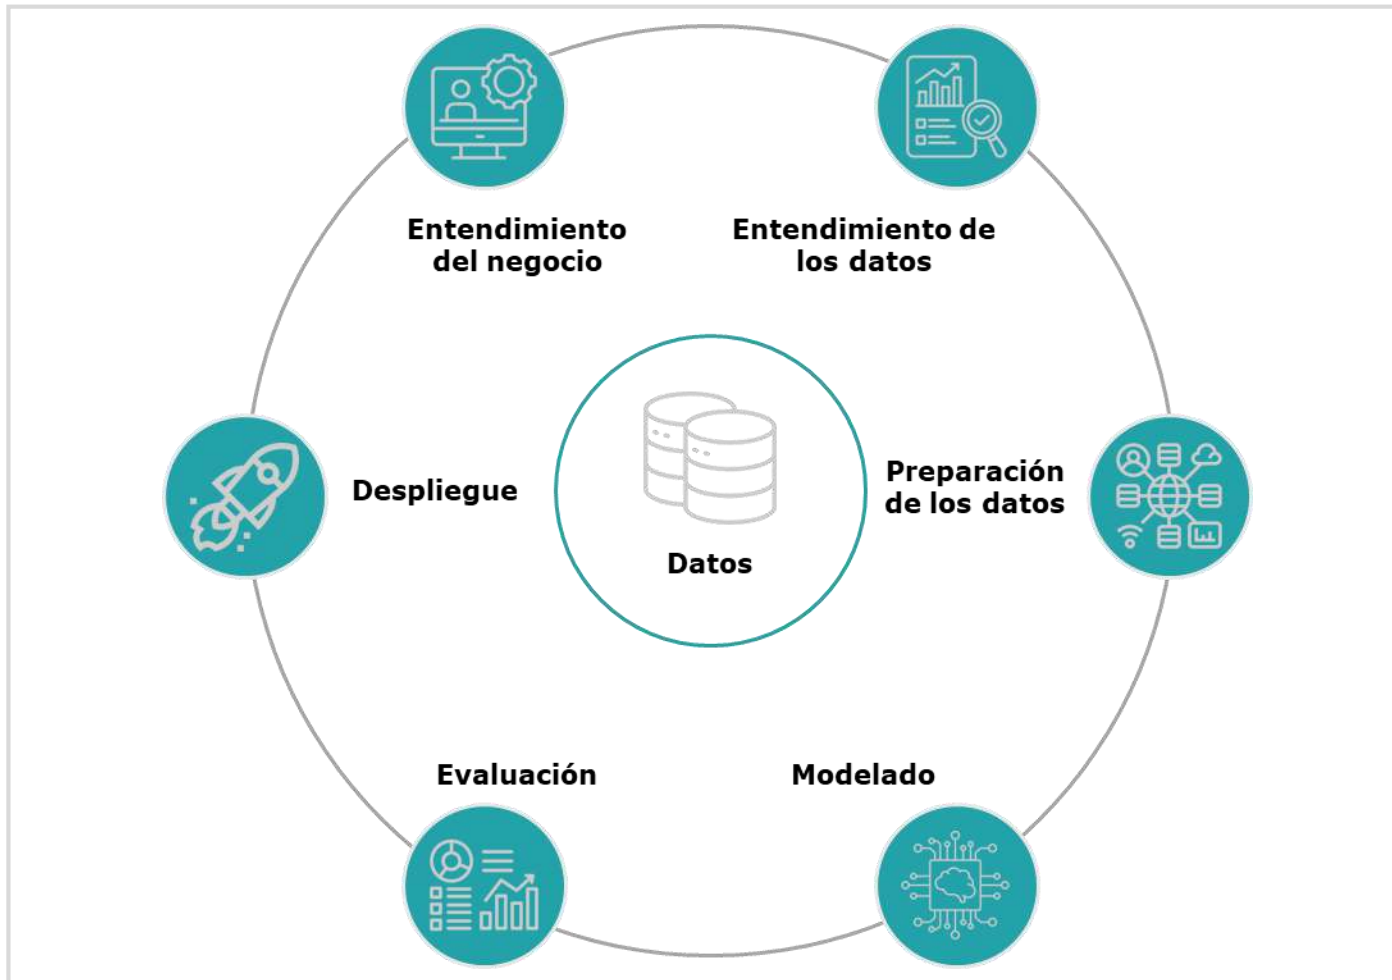
Metodología



Metodología

- Tesis cuantitativa, pudiendo siempre justificar los resultados de manera medible y comparable.
- Con base en la aplicabilidad de los resultados esperados se puede catalogar como investigación aplicada

Metodología



CRISP-DM (Wirth & Hipp, 2000)

- CRoss Industry Standard Process for Data Mining (CRISP-DM)
- La metodología estándar para la realización en investigaciones en las que se apliquen técnicas de minería de datos (Schröer et al., 2021)
- Metodología aplicada en diversos ámbitos (Schröer et al., 2021)

Metodología



1. **Entendimiento del negocio:** Centrado en el entendimiento del comportamiento de las personas clientes de la empresa objetivo.
2. **Entendimiento de los datos:** Con el fin de detectar las variables clave para la caracterización de la evolución de las personas clientes.
3. **Preparación de los datos:** Para poder entrenar los modelos propuestos en el marco científico.
4. **Modelado:** Centrada en la optimización de hiperparámetros de las propuestas realizadas para minimizar el error de predicción.
5. **Evaluación:** Que exponga de manera cuantitativa la consecución de los objetivos planteados.



**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea

Contexto de la investigación

Contexto de la investigación

- Empresas de servicios y retail de la Comunidad Autónoma de Euskadi.
- Se tratará de proponer técnicas que mediante la detección de patrones traten de inferir la posibilidad de fuga de los clientes
- Se definirá que se considera fuga o decrecimiento de compra en cada uno de los casos de estudio que se realicen para adaptarse a la realidad de cada uno de los sectores
- Se probarán distintas técnicas de impacto en los clientes categorizados como propensos a fugarse para ver el impacto que tienen las soluciones planteadas





**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea

Limitaciones

Limitaciones

- Ⓒ Será necesario hardware capaz de procesar una gran cantidad de datos.
- Ⓒ Necesario tener una considerable cantidad de datos para poder sacar todo el potencial de la metodología propuesta.
- Ⓒ Difícil definir el concepto de fuga en según qué contexto.





**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea

Bibliografía

Bibliografía

- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Bass, F. M., & Weitz, -Barton A. (1993). *The Future of Research Marketing Science*.
- Bernard H. Booms and Mary Jo Bitner. (1981). *Marketing Strategies and Organizational Structures for Service Firms*.
- Burez, J., & Van den Poel, D. (2007). CRM at a pay-TV company: Using analytical models to reduce customer attrition by targeted marketing for subscription services. *Expert Systems with Applications*, 32(2), 277–288. <https://doi.org/10.1016/j.eswa.2005.11.037>



Bibliografía

- C Capon, N., & Glazer, R. (1987). Marketing and Technology: A Strategic Coalignment. *Journal of Marketing*, 51(3), 1–14. <https://doi.org/10.1177/002224298705100301>
- C Chen, Y., & Iyer, G. (2002). Consumer addressability and customized pricing (Vol. 21, Issue 2).
- C Coussement, K., & Van den Poel, D. (2008). Churn prediction in subscription services: An application of support vector machines while comparing two parameter-selection techniques. *Expert Systems with Applications*, 34(1), 313–327. <https://doi.org/10.1016/j.eswa.2006.09.038>
- C Deng, L. (2012). Three Classes of Deep Learning Architectures and Their Applications: A Tutorial Survey.



Bibliografía

- Gadzama, W. A., Gabi, D., Argungu, M. S., & Suru, H. U. (2024). The use of machine learning and deep learning models in detecting depression on social media: A systematic literature review. In *Personalized Medicine in Psychiatry* (Vols. 45–46). Elsevier Inc. <https://doi.org/10.1016/j.pmip.2024.100125>
- Graves, A., Fernández, S., Gomez, F., & Schmidhuber, J. (2006). Connectionist temporal classification: Labelling unsegmented sequence data with recurrent neural networks. *ACM International Conference Proceeding Series*, 148, 369–376. <https://doi.org/10.1145/1143844.1143891>
- Gupta, S., Lehmann, D. R., & Stuart, J. A. (2004). Valuing Customers. *Journal of Marketing Research*, 41(1), 7–18. <https://doi.org/10.1509/jmkr.41.1.7.25084>
- Haines, G. H., Howard, J. A., & Sheth, J. N. (1970). The Theory of Buyer Behavior. *Journal of the American Statistical Association*, 65(331), 1406. <https://doi.org/10.2307/2284311>



Bibliografía

- Hastie Trevor, Tibshirani Robert, & Jerome Friedman. (2001). The Elements of Statistical Learning. <http://www.springer.com/series/692>
- Hinton, G. E., & Salakhutdinov, R. R. (2006a). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), 504–507. <https://doi.org/10.1126/science.1127647>
- Huang, M.-H., & Rust, R. T. (2020). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*. <https://doi.org/10.1007/s11747-020-00749-9/Published>
- Kamakura, W., Mela, C. F., Ansari, A., Bodapati, A., Fader, P., Iyengar, R., Naik, P., Neslin, S., Sun, B., Verhoef, P. C., Wedel, M., & Wilcox, R. (2005). Choice Models and Customer Relationship Management. *Marketing Letters*, 16(3–4), 279–291. <https://doi.org/10.1007/s11002-005-5892-2>



Bibliografía

- ◓ Lam, S. Y., Shankar, V., Erramilli, M. K., & Murthy, B. (2004). Customer value, satisfaction, loyalty, and switching costs: An illustration from a business-to-business service context. In *Journal of the Academy of Marketing Science* (Vol. 32, Issue 3, pp. 293–311). <https://doi.org/10.1177/0092070304263330>
- ◓ LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- ◓ Lemmens, A., Croux, C., & Leuven, K. U. (2007). Bagging and boosting classification trees to predict churn.
- ◓ Li, Z., He, Q., & Li, J. (2024). A survey of deep learning-driven architecture for predictive maintenance. *Engineering Applications of Artificial Intelligence*, 133, 108285. <https://doi.org/10.1016/j.engappai.2024.108285>



Bibliografía

- McCharty, E. J. (1964). *Basic Marketing: A Managerial Approach* (2nd Edition).
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- Neslin, S. A., Gupta, S., Kamakura, W., Junxiang, L. U., & Mason, C. H. (2006). Defection detection: Measuring and understanding the predictive accuracy of customer churn models. *Journal of Marketing Research*, 43(2), 204–211. <https://doi.org/10.1509/jmkr.43.2.204>
- Reinartz, W., Wiegand, N., & Imschloss, M. (2019). The impact of digital transformation on the retailing value chain. *International Journal of Research in Marketing*, 36(3), 350–366. <https://doi.org/10.1016/j.ijresmar.2018.12.002>



Bibliografía

- Rohhila, S., & Singh, A. K. (2024). Deep learning-based encryption for secure transmission digital images: A survey. *Computers and Electrical Engineering*, 116. <https://doi.org/10.1016/j.compeleceng.2024.109236>
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., & Manzagol, P.-A. (2010). Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion Pascal Vincent Hugo Larochelle Yoshua Bengio Pierre-Antoine Manzagol. In *Journal of Machine Learning Research* (Vol. 11).



Bibliografía

- Wang, C., Rao, C., Hu, F., Xiao, X., & Goh, M. (2024). Risk assessment of customer churn in telco using FCLCNN-LSTM model. *Expert Systems with Applications*, 248. <https://doi.org/10.1016/j.eswa.2024.123352>
- Weerakody, P. B., Wong, K. W., Wang, G., & Ela, W. (2021). A review of irregular time series data handling with gated recurrent neural networks. *Neurocomputing*, 441, 161–178. <https://doi.org/10.1016/j.neucom.2021.02.046>
- Wirth, R., & Hipp, J. (2000). CRISP-DM: Towards a Standard Process Model for Data Mining.





**Mondragon
Unibertsitatea**

Enpresagintza
Fakultatea



Eskerrik asko

Ander Juarez Mugarza
ajuarez@mondragon.edu

Bilbao AS Fabrik, Olagorta 26
48014 Bilbo
www.mondragon.edu