



FACULTAD DE CIENCIAS ECONÓMICAS Y EMPRESARIALES

# **ESTUDIO COMPARATIVO DEL ÉXITO DE LAS STARTUPS EN BASE A SU SECTOR**

Área de Modelos Cuantitativos para la Economía y la Empresa/ 5º E3 – C

Tutor: Eduardo César Garrido Merchán

Alumno: Elena Uríbarri Gutiérrez

Madrid

Junio 2022

## Resumen

En la actualidad del mundo laboral nos encontramos en la era del cambio, en la que tanto la innovación como la tecnología juegan un papel crucial. Los ecosistemas emprendedores están insurgiendo y el concepto de “startup” como modelo que reinventa el sistema tradicional aportando un valor añadido a numerosos productos y servicios ha llegado para quedarse. El crecimiento del número de startups y la retirada del mercado de otros tipos de empresa tradicionales provocan que su estudio sea muy relevante, por lo que es preciso comprender su modelo de negocio, así como sus factores de éxito o fracaso.

En el presente estudio se pretende analizar el éxito de las startups a partir de un modelo econométrico compuesto por la información de 257 startups, considerando así variables como la industria, el número de fundadores, la localización de la startup, etc. y midiéndolas respecto del número de rondas financiación obtenidas por la startup, considerando esta última variable como la independiente y la que mide su éxito. Para crear nuestro modelo utilizaremos la regresión de Poisson, interpretando así la significación de sus variables, analizando su multicolinealidad y observando su predicción. Finalmente realizaremos un pequeño modelo de *Machine Learning* en el que a partir de un *Decisión Tree* compararemos que modelo se ajusta mejor a nuestros datos.

**Palabras clave:** innovación, tecnología, startup, financiación, éxito, modelo econométrico, árbol de decisión, machine learning, regresión de Poisson.

## **Abstract**

Today's labour market is living an era of change, in which both innovation and technology play a crucial role. Entrepreneurial ecosystems are emerging and the concept of "startup" as a model that reinvents the traditional system by adding value to numerous products and services has come to stay. The growth in the number of startups and the withdrawal of other types of traditional companies from the market make their study very relevant, so it is necessary to understand their business model, as well as the factors regarding their success or failure.

This study aims to analyze the success of startups using an econometric model composed of information from 257 startups, considering variables such as industry, number of founders, location of the startup, etc. and measuring them with respect to the number of financing rounds obtained by the startup, considering this last variable as the independent one and the one that measures its success. To create our model, we will use Poisson regression, interpreting the significance of its variables, analyzing its multicollinearity, and observing its prediction. Finally, we will create a small Machine Learning model in which we will use a "Decision Tree" to compare which model best fits our data.

**Key words:** innovation, technology, startup, financing, success, econometric model, decision tree, machine learning, Poisson regression.

## ÍNDICE DE CONTENIDOS

<b>0. LISTADO DE SIGLAS Y CONTENIDOS</b> .....	8
<b>1. INTRODUCCIÓN Y OBJETIVOS DEL ESTUDIO</b> .....	9
<b>1.1. Motivación y contexto vigente</b> .....	9
<b>1.2. Organización del trabajo y metodología</b> .....	11
<b>2. ESTADO DEL ARTE</b> .....	14
<b>2.1. Factores de éxito y fracaso de las startups</b> .....	16
<i>2.1.1. El individuo</i> .....	16
<i>2.1.3. El entorno</i> .....	18
<i>2.1.4. El proceso</i> .....	19
<b>2.2. Importancia macroeconómica de las startups</b> .....	21
<i>2.2.1. Crecimiento económico</i> .....	21
<i>2.2.2. Tasa de desempleo</i> .....	22
<i>2.2.3. Productividad</i> .....	22
<i>2.2.4. Competitividad</i> .....	23
<i>2.2.5. P.I.B.</i> .....	23
<b>3. ALCANCE DEL PROYECTO</b> .....	24
<b>3.1. Pregunta de investigación, objetivos e hipótesis</b> .....	24
<b>3.2. Asunciones y restricciones</b> .....	26
<b>4. EL MODELO</b> .....	28
<b>4.1. Introducción</b> .....	28
<b>4.2. Variables empleadas y forma de medida</b> .....	28
<b>4.3. Estimación del modelo</b> .....	33
<i>4.3.1. Modelo binomial negativo:</i> .....	34
<i>4.3.2. Modelo de Poisson</i> .....	36
<i>4.3.3. Modelo MCO</i> .....	36
<b>4.4. Análisis del modelo</b> .....	38

<b>4.5. Interpretación de las variables</b> .....	39
<b>4.6. Multicolinealidad</b> .....	42
<b>4.7. Predicción</b> .....	43
<b>5. RESULTADOS DEL ESTUDIO</b> .....	43
<b>6. MACHINE LEARNING</b> .....	44
<b>7. CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN</b> .....	48
<b>8. REFERENCIAS BIBLIOGRÁFICAS</b> .....	51



## ÍNDICE DE TABLAS Y GRÁFICOS

### **Tablas**

Tabla 1: Análisis de variables.....	30
Tabla 2: Análisis de correlaciones entre variables .....	31
Tabla 3: Modelo Binomial Negativo .....	35
Tabla 4: Modelo de Poisson .....	36
Tabla 5: Modelo MCO .....	37
Tabla 6: Modelo de Poisson .....	39
Tabla 7: Modelo MCO sin la variable industria .....	41
Tabla 8: Análisis VIF .....	42

### **Gráficos**

Gráfico 1: Densidad Estimada de CBRank .....	32
Gráfico 2: Densidad estimada de Total Financiación.....	32
Gráfico 3: Densidad estimada de NARondas de Financiación.....	33
Gráfico 4: Estadístico para el contraste de normalidad .....	38
Gráfico 5: Scatterplot Industria .....	41
Gráfico 6: Predicción.....	43

### **Ilustraciones**

Ilustración 1: Orange Testing Process .....	45
Ilustración 2: Resultados de Orange .....	47

## **0. LISTADO DE SIGLAS Y CONTENIDOS**

- ONU: Organización de Naciones Unidas
- USD: United States Dollars
- CB: CrunchBase
- MCO: Mínimos Cuadrados Ordinarios
- VIF: Variance Inflation Factor
- MLG: Modelos Lineales Generalizados
- SUM: StartUp Mexico
- KNN: K Nearest Neighbours
- (R)MSE: (Root) Mean Squared Error
- MAE: Mean Absolute Error



# 1. INTRODUCCIÓN Y OBJETIVOS DEL ESTUDIO

## 1.1. Motivación y contexto vigente

Desde hace tiempo se viene escuchando el término “**startup**”. La primera startup surgió en la década de los años 50 en **Silicon Valley**<sup>1</sup>, Estados Unidos, y desde entonces este término anglosajón que significa literalmente “empezar” y “arriba” se ha ido incorporando en el resto del mundo. Este concepto engloba a aquellas empresas de base tecnológica que a partir de una idea innovadora buscan crear valor, mejorando un producto o servicio actual, o satisfaciendo una necesidad que hasta el momento no estuviera cubierta.

Una de las características principales de las startups es, a parte de su **base tecnológica**, su **escalabilidad**. Por escalabilidad entendemos la capacidad de la empresa de crecer rápidamente, aumentando a un ritmo superior los ingresos que los costes para así beneficiarse de las economías de escala. Las startups utilizan la **innovación** a partir de la tecnología para de esta manera conseguir unos modelos de negocio más eficientes: “Una startup es una empresa de base tecnológica que ofrece un nuevo producto o servicio utilizando el valor añadido de la tecnología incorporada. Esto se define como ‘innovación a través de la tecnología’.”<sup>2</sup> Esta cita confirma lo explicado en el párrafo.

Actualmente, en el **siglo XXI**, estamos viviendo un **cambio tecnológico acelerado** que comenzó en los 90, provocando transformaciones constantes en nuestro estilo de vida y un fuerte impulso de la economía mundial, pues los individuos se han acostumbrado a adaptarse a estos cambios generados por el emprendimiento y la innovación. Como ejemplo de esto, las personas, en el plano individual, utilizamos **internet** en nuestra rutina. Se ha convertido en un hábito utilizar el móvil para reservar en un restaurante, pedir comida a domicilio, realizar gestiones bancarias, mirar el tiempo, etc. Esto ha dado lugar a cambios sociales, con **nuevas demandas por parte de los consumidores**, llevando a las empresas a adoptar nuevos modelos de negocio que

---

<sup>1</sup> Baliño, A. (2021, 29 junio). *El origen de las Startups*. Hugo de la O. (disponible en: <https://hugodelao.com/que-es->)

<sup>2</sup> Kopera, S.; Wszendybył-Skulska, E.; Cebulak, J.; Grabowski, S. (2018) Interdisciplinarity in Tech Startups Development—Case Study of ‘Unistartapp’Project., 1–10.

aprovechan la globalización y utilizan internet como herramienta útil para la escalabilidad de sus actividades comerciales. Por tanto, observamos cómo la tecnología ha cambiado la forma en la que nos relacionamos, en la que compramos y en la que vivimos. Los individuos, la sociedad, las empresas, los gobiernos, los países, las relaciones internacionales, etc. se encuentran en un uso continuo de la tecnología.

Consecuentemente, el **espíritu empresarial** se está reconociendo como uno de los factores más importantes en la promoción del desarrollo económico, la creación de empleo, la integración social y la igualdad económica. Por estos motivos la creación de nuevos negocios despierta el interés de políticos, académicos y organismos internacionales. La Organización de Naciones Unidas (ONU) aprobó la Resolución 67/2012 “**Emprendimiento para el Desarrollo**” en el año 2012, reconociendo formalmente el espíritu empresarial como una herramienta importante para reducir la pobreza, crear un desarrollo sostenible y revitalizar el medio ambiente.

La existencia de las startups está **revolucionando la manera de trabajar** de las personas, aportándoles mayor flexibilidad y un modelo de trabajo adaptado a las necesidades humanas y laborales. Ya no es el objetivo de todos los trabajadores formar parte de grandes corporativas y acudir a la oficina cada día. Nos encontramos en un ecosistema global emprendedor en el que muchos de los puestos laborales presentes hoy van a dejar de existir en un futuro. La era digital está cambiando el mundo tal y como lo conocemos y es importante entenderla y apoyarla si no queremos quedarnos atrás como país, como empresa o como persona. Los procesos se están automatizando y las empresas se están digitalizando.

Las startups están teniendo tanto éxito porque transforman modelos de negocio tradicionales, adaptándose a las necesidades y usos de las personas en la era tecnológica. Están surgiendo startups a diario y desapareciendo otro tipo de empresas. Sin embargo, como podemos observar, las startups han llegado para quedarse. Por tanto, estudiar las **causas de éxito y fracaso de las startups**, así como analizar aquellas que han logrado sobrevivir, es indispensable. Dentro de estos factores se encuentran: la experiencia previa de los fundadores en las industrias donde la startup desarrolla su actividad; el capital invertido; la tecnología con la que cuenta la startup, etc. Ejemplos de empresas que comenzaron como startups son Facebook, Instagram, WhatsApp y Glovo.

En este estudio **vamos a analizar el éxito de las startups** en base a su sector y otras variables a partir de información real y actualizada sobre startups operativas. Con este análisis pretendemos comprender si factores como la localización, el número de empleados, el número de fundadores, el sector de actividad, etc. de la startup influyen en la obtención de financiación necesaria para el desarrollo de su actividad. A través de la obtención de rondas de financiación mediremos su éxito. Para ello realizaremos modelos econométricos y analizaremos los resultados obtenidos.

Como se descubrirá en el siguiente apartado, el trabajo constará de un estudio del entorno y del estado del arte, proseguido del alcance del proyecto, en el que se hablará sobre las preguntas de investigación y las hipótesis. El cuarto punto será el modelo elaborado a través de *Gretl*, continuado por los resultados y su consecuente análisis. Para finalizar se realizará un modelo de *machine learning* para contrastar resultados.

## 1.2. Organización del trabajo y metodología

Tras introducir el contexto en el que se encuentran las startups, procedemos a explicar cómo vamos a vertebrar nuestro trabajo. Lo primero para la realización del estudio fue la **elección del tema**. Existen numerosos estudios e informes acerca de los factores de éxito y de fracaso de las startups, y como resultado de su lectura y entendimiento, elegimos realizar un modelo econométrico relacionado con estos factores, centrándonos en explicar qué factores influyen en la obtención de financiación de las startups, y más concretamente en si esta obtención de financiación varía según el ámbito de actividad de la startup. Lo que aporta nuestro estudio es por tanto el **énfasis del éxito de una startup es su número de rondas de financiación obtenidas**, puesto que se considera que la cantidad de financiación es relativa al existir startups que necesitan unas inversiones mayores para operar que otras.

Por lo tanto, en una primera instancia se realizará el “**estado del arte**” en el que vamos a hacer un breve repaso de la literatura escrita por los estudiosos acerca de los factores que influyen en el éxito de las startups, mencionando aquellos más repetidos, debido a su posterior aparición como variables de nuestro modelo econométrico. Entre los **factores** tendremos en cuenta los **relativos al individuo, a su entorno y al proceso**. En este mismo apartado mencionaremos la importancia macroeconómica de la creación de startups, para entender la envergadura de su estudio.

Posteriormente se **establecerá nuestro modelo econométrico** y en el “**alcance del trabajo**” se definirán sus objetivos e hipótesis, asunciones y restricciones. En el caso del modelo del presente estudio, el objetivo principal es determinar si el hecho de que **la industria** en la que la startup desarrolla su actividad sea tecnológica o no influye en la obtención de financiación de las startups. Además, para comprobar la veracidad del resto de las hipótesis planteadas utilizaremos tres tipos de modelos diferentes; el de mínimos cuadrados ordinarios, el de Poisson y el binomial negativo.

En tercer lugar, se realizará el “**modelo econométrico**”. Es necesario recordar que un modelo es una representación simplificada de la realidad, y en el caso del modelo del presente estudio recogemos la información de 257 startups simbolizando la realidad. En nuestro estudio analizamos el éxito de las startups en base a su sector de actividad, por lo que se ha reunido la información de diversas startups representando distintos sectores de actividad, dividiendo así las startups en **dos grupos**; startups de industrias tradicionales y startups de industrias modernas.

El primero de los dos grupos realizado está conformado por las startups que consideramos “**tradicionales**”, siendo estas aquellas que, aún tecnológicas pues todas las startups lo son, desarrollan su actividad en una industria que lleva existiendo mucho tiempo. Un ejemplo de esto ería Airbnb que, aunque hoy es una gran empresa, comenzó como una startup. Airbnb ofrece un servicio de alquileres de alojamientos a través de una plataforma online o una aplicación móvil, permitiendo así que dicho alojamiento pueda ser reservado por otras personas como si de un hotel se tratase. Este grupo lo forman las industrias de deportes, viajes, turismo, moda, educación y salud.

El segundo grupo lo formarán las startups consideradas “**modernas**” siendo estas aquellas que desarrollan su actividad en industrias tecnológicas. Un ejemplo de este tipo de startups es “*Republic*”, que brinda acceso a las personas alrededor del mundo a la posibilidad de invertir en otras startups, cripto monedas y videojuegos<sup>3</sup>. Las industrias que componen este conjunto son las de inteligencia artificial, análisis de datos, software, *Fintechs*, *blockchain*, criptomonedas, videojuegos y entretenimiento digital.

Vamos a definir algunos de los términos del párrafo anterior para el correcto entendimiento de esta división de industrias. Las “**FinTechs**” son empresas innovadoras

---

<sup>3</sup> *Republic - Crunchbase Company Profile & Funding*. (2022). Crunchbase. <https://www.crunchbase.com/organization/republic-co>

que nacen en forma de startups especialistas en áreas determinadas de los servicios financieros. Se refieren a la tecnología financiera, y cubren todo el alcance de los servicios y productos proporcionados tradicionalmente por la industria de los servicios financieros, no solo ciertos ámbitos de esta como serían la financiación o los préstamos.<sup>4</sup> El “*blockchain*”, que traducido al español significa “cadena de bloques”, se puede definir como la simple estructura de datos utilizada para registrar transacciones.<sup>5</sup> Para entender el concepto de *blockchain* habría que imaginarse un libro compartido en el que hay entidades a las que se les permite escribir las transacciones realizadas entre usuarios. Estos usuarios también podrían verificar su identidad y acceder a este permiso para así entre todos regular las transacciones. De esta manera la información estaría verificada por todos los que forman parte de las transacciones. Lógicamente, el término tiene una envergadura mayor, pero aquí nos limitamos a entender el concepto. Finalmente están las “**criptomonedas**”, que son monedas virtuales que representan al dinero de forma digital, pudiendo utilizarse como sistema de pago y permitiendo el intercambio de dinero de manera segura y anónima sin requerir a intermediarios como los bancos. Estas operan a través del *blockchain*, creándose así un registro público de todas las compras y ventas de criptomonedas.<sup>6</sup>

Para la realización del modelo se ha recogido la **información de un total de 257 startups**, descargando los datos de la plataforma profesional “*Crunchbase*”<sup>7</sup>. Se debe tener en cuenta que los datos están descargados a fecha 21/02/2021 y que se han cambiado todas las cantidades monetarias por el tipo de cambio de oficial a USD a fecha 07/03/2022. Estos datos son de corte transversal (distintas startups en un momento determinado), y se han utilizado como unidades observacionales a las startups individualmente. También se han escalado las variables “número de empleados” y “número de fundadores”, restándoles su media y dividiéndolas por su desviación típica, pues esto tiene la ventaja de comparar sus efectos, al permitir contrastar los coeficientes entre sí para ver cuál es más relevante. (Aunque esto complica un poco la interpretación

---

<sup>4</sup> Arner, D. W., Barberis, J., & Buckley, R. P. (2015). The evolution of Fintech: A new post-crisis paradigm. *Geo. J. Int'l L.*, 47.

<sup>5</sup> Ghio, L., Restuccia, F., D'Oro, S., Basagni, S., Melodia, T., Maccari, L., & Cigno, R. L. (2021). What is a Blockchain? A Definition to Clarify the Role of the Blockchain in the Internet of Things. *arXiv preprint arXiv:2102.03750*.

<sup>6</sup> Wątarek, M., Drożdż, S., Kwapien, J., Minati, L., Oświęcimka, P., & Stanuszek, M. (2021). Multiscale characteristics of the emerging global cryptocurrency market. *Physics Reports*, 901, 1-82.

<sup>7</sup> *Crunchbase: Discover innovative companies and the people behind them.* (2022). Crunchbase.

<https://www.crunchbase.com/>

porque ahora al tener la variable tipificada, se interpretaría como una variación de una desviación típica respecto a la media y no de un punto). Se trabajará con estos datos a través del programa “*Gretl*”.

Una vez se ha explicado que hay muchos factores influyen en el éxito de las startups, la división en función del sector de actividad y plataforma utilizada para la obtención de datos, se procederá a realizar un modelo econométrico para explicar y comprobar si las hipótesis se cumplen. El objetivo principal de este trabajo es comprobar la veracidad de nuestra hipótesis principal, consistente en que las startups que hemos considerado modernas tienen más éxito que las consideradas tradicionales. Además, tenemos otras hipótesis que comprobar, como la influencia de variables como el lugar de nacimiento de la startup o el número de empleados que trabajan en ella sobre el número de rondas de financiación obtenidas por la startup.

Para validar nuestras hipótesis se realizarán **varios modelos**, siendo el principal una **regresión de Poisson** cuya variable explicada será el número de rondas de financiación obtenidas por la startup, al ser esta un indicador del éxito de estas pues si la startup no presenta proyecciones de crecimiento económico es poco probable que reciba la financiación buscada en la ronda. Sin embargo, como podremos ver más adelante en el apartado de “**resultados del modelo**”, nuestra hipótesis principal no se valida, por lo que el hecho de que la actividad de la startup se desarrolle en industrias modernas no influye en su éxito. Después analizaremos los resultados de nuestro modelo, que como veremos, conllevan a que varias de nuestras hipótesis no se puedan validar. Por lo tanto, realizaremos un pequeño modelo de *Machine Learning* con el que a partir de un *Decision Tree*, un *Random Forest* y un *Knn*<sup>8</sup> obtendremos un RMSE que nos indicará que este modelo se ajusta mejor que el de regresión. Finalmente se sentarán las conclusiones y estableceremos las posibles futuras líneas de investigación.

## 2. ESTADO DEL ARTE

El ser humano ha demostrado a lo largo de la historia una constante necesidad de estudiar y analizar aquello que es nuevo y ocurre a su alrededor. Existe, por tanto,

---

<sup>8</sup> Shane T, M. (2021, 24 febrero). *Decision Trees, Random Forests, and Nearest-Neighbor classifiers*. Decision Trees, Random Forests, and Nearest-Neighbor classifiers. <https://pages.mtu.edu/%7Eshane/psy5220/daily/Day13/treesforestsKNN.html>

multitud de literatura e investigación acerca de las **startups** y, más concretamente, sobre los **factores que provocan su éxito o fracaso**. Así, en este apartado del estudio en cuestión, se destacarán algunos de ellos. A nuestro parecer, estos estudios son fundamentales, pues permiten a aquellas **personas** que quieren crear una startup tener en cuenta qué factores van a contribuir a su éxito y cuáles les pueden perjudicar. También los **gobiernos y empresas** están interesados en estos factores, pues saber qué puede favorecer o perjudicar a sus habitantes es imprescindible para establecer las políticas macroeconómicas de un país, para regular la competencia, fomentar la creación de empleo y establecer el crecimiento económico.

En este sentido es difícil establecer una única definición de startup exitosa, pues muchos estudiosos del tema coinciden en que el éxito se basa en el *exit*<sup>9</sup> de la startup, es decir, el dinero por el que otra compañía la compra. De forma paralela se podría entender que el éxito de la startup reside en su salida a bolsa, en cuyo caso se conoce a las startups como “unicornios”<sup>10</sup>. Sin embargo, hay otras opiniones en las que el éxito se basa en lograr crear algo por uno mismo, mejorando la vida de los demás y simplificando los métodos tradicionales de hacer las cosas.<sup>11</sup>

Por su parte, el conocimiento de estos factores de éxito o fracaso de las startups resulta importante también para los **inversores**, ya que temen el riesgo asociado a invertir en startups y empresas cuya rentabilidad no es aún sostenible. La crisis crediticia de 2008 y 2009 ha provocado que los bancos se hayan vuelto reacios al riesgo a la hora de prestar dinero a las nuevas startups.<sup>12</sup> Ahora los bancos acceden a prestar financiación bajo condiciones más seguras, convirtiendo en un verdadero reto la obtención de financiación para los emprendedores.

La conocida cita “9 de cada 10 startups fracasan” ha sido renovada en el Startup Genome Report de 2019, estableciendo que 11 de cada 12 startups fracasan<sup>13</sup>, por tanto, nos preguntamos: ¿Qué factores influyen en el éxito de una startup? Como es lógico, son muchísimos los factores que pueden afectar a la viabilidad de una startup, por lo que nos

---

<sup>9</sup> Caballero, A. (2022, 24 mayo). *¿Qué es el exit de una startup y qué opciones hay?* Keiretsu Forum Spain. <https://www.keiretsuforum.es/emprendedor/que-es-el-exit-de-una-startup-y-que-opciones-hay/>

<sup>10</sup> Martínez, C. R. (2022, 15 marzo). *¿Qué es una empresa unicornio? Las startups que más han triunfado*. Thinking for Innovation. <https://www.iebschool.com/blog/companias-unicornio-lean-startup/>

<sup>11</sup> Santisteban, J., & Mauricio, D. (2017). Systematic Literature Review of Critical Success Factors of Information Technology Startups. *Academy of Entrepreneurship Journal*, 23.

<sup>12</sup> Nutting, W., & Hubbard, D. (2009). Addresses by William Nutting and David Hubbard Nutting. *BiblioBazaar*, 53. (1-96).

<sup>13</sup> Cerdeira, N., & Kotashev, K. (2021). Startup Failure Rate: Ultimate Report + Infographic. (Obtenido de Failory: <https://www.failory.com/blog/startupfailure-rate> )

centraremos en los más repetidos en los estudios realizados. Estos **factores** pueden surgir en **diferentes momentos** de la vida de la startup; hay factores que surgen con anterioridad al nacimiento de la startup, otros durante su creación, y otros tras ella. Además, el éxito o fracaso de una startup no se debe a un único factor, sino a la suma de varios de ellos. Para seguir un orden respecto a la revisión de la literatura dividiremos los factores en 3 grupos: el individuo, el entorno y el proceso. Finalmente concluiremos con la importancia macroeconómica de las startups.

## 2.1. Factores de éxito y fracaso de las startups

### 2.1.1. El individuo

El fundador o los fundadores de una startup juegan un papel crucial en el éxito de la misma<sup>14</sup>. Las personas tenemos unas **características psicológicas** inherentes a nosotros mismos que nos hacen diferentes, entre ellas muchas están **relacionadas** con la **capacidad de emprender**, como la motivación, la ambición, la responsabilidad y la persuasión. Sin embargo, se ha comprobado que “la psicología del emprendedor es más importante para predecir las posibilidades de crear una empresa que para predecir las posibilidades de éxito de esta”.<sup>15</sup> Con respecto al individuo también parece relevante la **edad**. “Los empresarios más viejos son generalmente más cautelosos y conservadores”.<sup>16</sup> Es por ello por lo que se encuentran más emprendedores **jóvenes** que adultos, pues su grado de apertura hacia la aversión es mayor.<sup>17</sup>

Otra de las características relevantes del individuo es su **experiencia en la industria y su experiencia laboral**, si el equipo que forma y dirige la startup no tiene experiencia previa en la industria en la que esta se desenvuelve, las probabilidades de

---

<sup>14</sup> The IT Factory. (2019, 29 diciembre). *A importância da equipa de trabalho para o sucesso de uma startup*. Startup Knowledge Base. <https://www.the-itfactory.com/startup-knowledgebase/article/importance-of-teamwork/>

<sup>15</sup> Rauch, A., & Frese, M. (2000). Psychological approaches to entrepreneurial success: A general model and an overview of findings. *International review of industrial and organizational psychology*, 15, 101-142.

<sup>16</sup> Vaillant, Y., Gómez, E., & Lafuente, E. (2011). El impacto de factores socio-culturales sobre la actividad emprendedora de los jóvenes en España.

<sup>17</sup> Bartesaghi, A., Lasio, V., Varela, R., Veiga, L., Kew, P. (2016) GEM América latina y el Caribe 2015-2016, *Global Entrepreneurship Monitor*, (disponible en: <https://www.gemconsortium.org/file/open?fileId=49822&ga=2.184450862.985493710.1647513366-1856045328.1647513366> )



fracaso son mayores, al no entender su funcionamiento, sus tendencias y sus riesgos. Marcus Dantus, el director de Startup México (SUM) considera que es más relevante la experiencia en la industria que el conocimiento técnico de esta: “para ser emprendedor debe gustarte lo que haces, pero no sólo eso, debes dominarlo, y eso muchas veces sólo te lo da la experiencia en las industrias en las que se quiere emprender. No es un camino que pueda tomarse a la ligera y no todos pueden lograrlo”<sup>18</sup>. Adicionalmente, la experiencia laboral no es necesaria únicamente en el sector en cuestión, sino que también es importante la experiencia previa como **directivo** y como **emprendedor**. Los emprendedores son aquellas personas que inician un negocio por sus propios medios, y esta experiencia está llena de aprendizaje sin importancia de cual sea el sector en concreto en el que se emprende, ya que al crear algo de cero son muchas las cosas que van a ir mal y de las que se va a aprender. En relación con lo anterior también son importantes los estudios universitarios del fundador, pues hay una gran diferencia entre aquellos que cuentan con estudios y los que no, proliferando más aquellas personas con uno o más años de estudios universitarios.<sup>19</sup>

Hay que tener en cuenta, por supuesto, quienes son los **fundadores** de la startup. Para que la startup tenga el mayor éxito posible, es preciso que las personas que la fundaron dediquen su **actividad laboral completa** al desarrollo de la startup. Cada vez es más común que los inversores desconfíen de depositar su dinero en startups en las que los propios fundadores no son capaces de invertir su tiempo. Es decir, es relevante el hecho de que los fundadores de la startup se dediquen laboralmente a su desarrollo. De hecho, no está valorado positivamente que aun dedicándose a su propia startup, sigan manteniendo otro trabajo.<sup>20</sup> Además, “las empresas fundadas por **más de un individuo** suelen tener mejores perspectivas de crecimiento pues la existencia de un equipo emprendedor permite acceder a una mayor variedad de recursos, desarrollar más capacidades, y compartir riesgos y responsabilidades que llevan a fijarse objetivos más ambiciosos”.<sup>21</sup> Además un equipo debe ser lo suficientemente grande para cumplir con

---

<sup>18</sup> Eleconomista.Com.Mx Aenolastname. (2022). *La experiencia laboral es fundamental para emprender*. AméricaEconomía | AméricaEconomía. <https://www.americaeconomia.com/articulos/notas/la-experiencia-laboral-es-fundamental-para-emprender>

<sup>19</sup> Lussier, R. N. (1995). Startup business advice from business owners to would-be entrepreneurs. *SAM Advanced Management Journal*, 60, 10.

<sup>20</sup> Alsos, G. A., & Kolvareid, L. (1998). The business gestation process of novice, serial, and parallel business founders. *Entrepreneurship Theory and Practice*, 22, 101-114.

<sup>21</sup> Terjesen, S. & Szerb, L. (2008). Dice thrown from the beginning? An empirical investigation of determinants of firm level growth expectations. *Estudios de Economía*, 35, 154-178.

las tareas simples que precisa un emprendimiento, pero no más, pues su eficiencia se vería reducida.<sup>22</sup> (Hackman & Oldham, 1982) En línea con lo anterior, es importante que los integrantes de la startup estén unidos, que el equipo sea productivo, que haya roles variados y que mantengan una buena comunicación entre sí.

### **2.1.3. El entorno**

Los **factores sociodemográficos y políticos** son cruciales para el éxito o fracaso de una startup, se trata de aquellos factores externos a la startup pero que afectan a su éxito como, por ejemplo, la cultura, las leyes, las tasas impositivas, etc. Las **políticas gubernamentales** suponen una gran limitación en la decisión de financiación de los inversores, pues estas **condicionan** que **la inversión** en startups sea atractiva o no. Un ejemplo de esto es Singapur, que estableció su política de gobierno en torno al crecimiento económico impulsado por la innovación, atrayendo así oportunidades de inversión. “Las políticas gubernamentales, como la reducción de los impuestos de sociedades, la provisión de oportunidades de financiación, los créditos fiscales, los derechos de propiedad intelectual y la legislación antimonopolio, son ejemplos de las políticas que existen para proteger a los pequeños actores activos en el mercado de las empresas emergentes, creando así unas condiciones equitativas para fomentar una competencia sana.”<sup>23</sup>

En relación con el párrafo anterior, es imprescindible mencionar la **localización geográfica de la startup**, pues está demostrado que aquellas que están situadas en *clusters* (grupos) tienden a ser más exitosas, pues tienen ciertas ventajas como el acceso a una mejor y más amplia red de contactos, absorber conocimientos externos e incluso la cercanía a proveedores especializados.<sup>24</sup> Por ello, lugares como Silicon Valley facilitan tanto la creación como el apoyo entre startups.

Otro factor que hay que tener en cuenta en este apartado es **el entorno del producto o servicio**, pues si este se encuentra en un mercado en el que el producto está

---

<sup>22</sup> Hackman, J., & Oldham, G. (1982). Work Redesign. *Group & Organization Studies*, 7.

<sup>23</sup> Dolfma, W. and Seo, D. (2013). Government policy and technological innovation—a suggested typology. *Technovation*, pp.173-179.

<sup>24</sup> Barringer, B., Foard, J., & Neubaum, D. (2005). A Quantitative Content Analysis of the Characteristics of Rapid-Growth Firms and Their Founders. *Journal of Business Venturing*, 20, 663-687. (Obtenido de: [https://www.researchgate.net/publication/222426972\\_A\\_Quantitative\\_Content\\_Analysis\\_of\\_the\\_Characteristics\\_of\\_Rapid-Growth\\_Firms\\_and\\_Their\\_Founders](https://www.researchgate.net/publication/222426972_A_Quantitative_Content_Analysis_of_the_Characteristics_of_Rapid-Growth_Firms_and_Their_Founders) )

en etapa de crecimiento tendrá más posibilidades de éxito que si se encuentra en uno en el que el producto es totalmente nuevo o antiguo. Un claro ejemplo de esto sería “Bolt”, una startup que se ha integrado en el mercado de Cabify y Uber, y al considerarse este un servicio de movilidad antiguo, “Bolt” no ha tenido mucha cabida pues Cabify y Uber contaban con la fidelidad de la mayoría del mercado.

Finalmente encontramos **el sector en el que opera la startup** como otro factor de éxito o fracaso, pues “el rendimiento de una empresa de nueva creación es muy diferente según el sector en el que opere.”<sup>25</sup> Las startups por definición son de base tecnológica, lo cual las hace “modernas” pero esto no implica que la industria lo sea. Es decir, puede haber una startup que dedique su actividad al alquiler de apartamentos, industria que lleva existiendo cientos de años, igual que puede haber otra startup cuya actividad sea visitar museos a través de la realidad virtual, pero la realidad virtual es algo muy reciente que no existía hace cien años. Al ser la intención de mi trabajo demostrar la diferencia en el éxito de startups enfocadas en industrias modernas con aquellas enfocadas en industrias tradicionales, muchos de los factores mencionados anteriormente saldrán a relucir.

#### ***2.1.4. El proceso***

Las startups tienen que estar bien estructuradas desde su inicio. De hecho, existe un método denominado “*lean startup*” que ayuda a crear empresas de éxito utilizando un conjunto de técnicas probadas basadas en la innovación continua.<sup>26</sup> Por otro lado, existen otros factores determinantes en el éxito de las startups relativos a su proceso. Entre ellos encontramos el **capital**; aquellas empresas que comienzan con poco capital tienen más posibilidades de fracasar que las que empiezan con un capital adecuado. E igualmente sucede durante el resto del proceso, pues si las empresas van recibiendo un flujo continuo de capital podrán ir actualizándose, garantizando así su crecimiento. En relación con lo anterior es importante tener en cuenta que “aquellas empresas que se financiaron únicamente con fondos propios lograron menores niveles de crecimiento”<sup>27</sup> y que “uno

---

<sup>25</sup> Roure, J., & Keeley, R. (1990). Predictors of Success in new technology based ventures. *Journal of Business Venturing*, 5, 4-15. (Obtenido de: [https://econpapers.repec.org/article/eeeejvent/v\\_3a5\\_3ay\\_3a1990\\_3ai\\_3a4\\_3ap\\_3a2\\_01-220.htm](https://econpapers.repec.org/article/eeeejvent/v_3a5_3ay_3a1990_3ai_3a4_3ap_3a2_01-220.htm) )

<sup>26</sup> Ries, E., & Sařbut, B. (2012). El método lean startup.

<sup>27</sup> Otero, A. (2011). Factores claves en el proceso de acceder a recursos financieros en Colombia para nuevos empresarios. *Memorias XXI Congreso Latinoamericano sobre Espiritu Empresarial*. (Disponible en: [http://bibliotecadigital.icesi.edu.co/biblioteca\\_digital/bitstream/item/5387/1/7P8.pdf](http://bibliotecadigital.icesi.edu.co/biblioteca_digital/bitstream/item/5387/1/7P8.pdf) )

de los factores de las empresas innovadoras dinámicas es tener **diversas vías de financiamiento**”.<sup>28</sup>

Respecto a la **tecnología** se puede decir que la inteligencia artificial, los procesos de aprendizaje automático y los conocimientos tecnológicos de los directivos de las startups son factores clave para que éstas tengan éxito. Como se ha mencionado anteriormente, las startups son de base tecnológica, y si no se tienen los conocimientos básicos de esta tecnología que se quiere aplicar sobre el producto o servicio, esta fallará desde la base. Un buen uso de la tecnología es clave, pues esta puede ayudar a identificar los comportamientos del ser humano en el futuro, predecir las tendencias del sector en el que la startup se desarrolla, aumentar la eficiencia de los procesos y proporcionar analíticas respecto los resultados. Es imprescindible mantener la startup en una continua evolución tecnológica.<sup>29</sup>

El **control financiero** es a su vez muy relevante, las empresas que carecen de registros financieros precisos y actualizados de su actividad tienen mayores probabilidades de fracaso, así como aquellas que no efectúan planes de negocio específicos. Lo más recomendado es realizar proyecciones financieras a 5 años, permitiendo así al equipo que conforma la startup saber cuáles son sus objetivos, y en caso de estar alejados de ellos, tomar las medidas adecuadas.

Finalmente cabe mencionar que las empresas que comercializan en **mercados externos** presentan a nivel general tasas de crecimiento más altas. “Tienen que enfrentarse a barreras de entrada importantes, además, enfrentan una mayor competencia lo que los lleva a desarrollar una ventaja competitiva fuerte y, en general, tienen una mayor probabilidad de obtener ganancias importantes”.<sup>30</sup>

Como hemos visto, **son muchos los factores que afectan al éxito** o fracaso de una startup y es inabarcable mencionar todos en este estudio concreto por espacio y tiempo, sin embargo, si es necesario tenerlos en cuenta a la hora de emprender, invertir o establecer medidas gubernamentales. Estos factores han sido estudiados con anterioridad y se sabe de su certeza, por lo que con nuestro modelo procederemos a estudiar si existe

---

<sup>28</sup> Capelleras, J. y Kantis, H. (2009). Nuevas empresas en América Latina: factores que favorecen su rápido crecimiento. *Universidad Autónoma de Barcelona*. España.

<sup>29</sup> Saura, J. R., Palos-Sanchez, P., & Grilo, A. (2019). Detecting indicators for startup business success: Sentiment analysis using text data mining. *Sustainability*, 11, 917.

<sup>30</sup> Acs, Z., Morck, R., Shaver, J. & Yeung, B. (1997). The internationalization of small and medium-sized enterprises: a policy perspective. *Small Business Economics*, 9, 7-20.

una diferencia en el éxito o fracaso de las startups según la industria en la que desarrollan su actividad.

## **2.2. Importancia macroeconómica de las startups**

Como ya hemos mencionado, las startups presentan mucho interés a nivel macroeconómico, y esto se debe a los múltiples **beneficios** que aportan a los países en que estas se desarrollan. Entre estos beneficios encontramos el crecimiento económico del país, la reducción de la tasa de desempleo, y el aumento de la productividad, la competitividad y el PIB.

### **2.2.1. Crecimiento económico**

Las startups tienen mucho **potencial para hacer crecer los distintos sectores de mercado**. Estas, a partir de la innovación buscan aportar un valor añadido a las empresas y así transformar la economía. Por lo tanto, como nuevo agente que entra a operar en el mercado, estas generan impuestos, aumentan la empleabilidad, ofrecen nuevas oportunidades de inversión a los bancos, aportan riqueza a los emprendedores, y se alían con grandes empresas para realizar partes de su actividad de manera más eficiente y concreta. De esta manera mejoran la rentabilidad de muchas empresas y además desarrollan productos y servicios nuevos para las personas.

Además, las startups **favorecen el desarrollo tecnológico**, lo cual reporta mejoras al país y le ayudan a obtener un mejor posicionamiento en los rankings comparativos, como por ejemplo en el del barómetro de la innovación. Son por tanto un agente importante para el crecimiento económico de las economías emergentes.<sup>31</sup> Por otro lado, las startups, al basar sus actividades en el uso de la tecnología con ideas novedosas, atraen a inversores nacionales y extranjeros.<sup>32</sup> Esta atracción de inversiones impulsa la economía del país. Un ejemplo de la aportación de las startups en el crecimiento de las economías es su actuación a raíz de la crisis provocada por el Covid. El Covid 19 ha tenido un gran impacto económico y ha provocado una situación de crisis que ha estimulado a los emprendedores a crear startups para aprovechar las oportunidades que la adaptabilidad y

---

<sup>31</sup>Salamzadeh, A., Kawamorita Kesim, H. (2015). Startup Companies: Life Cycle and Challenges, *4th International Conference on Employment, Education and Entrepreneurship (EEE)*.

<sup>32</sup> Szarek, J., & Piecuch, J. (2018). The importance of startups for construction of innovative economies.

maleabilidad de sus modelos comerciales ofrecen.<sup>33</sup> Este surgimiento de nuevas startups representa su aportación a la revitalización de la actividad económica.

### ***2.2.2. Tasa de desempleo***

Las startups pertenecen a la nueva **economía emergente** y fomentan la creación de empleo.<sup>34</sup> Mediante el apoyo financiero de instituciones del gobierno, o a través de inversiones públicas o privadas, las startups captan el dinero necesario para su crecimiento. En el momento en el que **crecen**, necesitan **emplear a más personas**, por lo que son una buena solución al desempleo. Además, han demostrado tener una alta capacidad para generar empleo de calidad. En Estados Unidos el mercado de trabajo ha sufrido un cambio estructural a raíz de las políticas establecidas para fomentar la creación de startups, y estas han creado el 70% de los nuevos empleos estos últimos años.<sup>35</sup> Este cambio estructural se está produciendo también en el resto del mundo. En Europa, por ejemplo, las startups generaron 5 millones de puestos de trabajo en 2018.<sup>36</sup> Las startups tienen a su vez inconvenientes, pues este tipo de empresas son muy volátiles y la mayoría de ellas no alcanzan los 5 años de vida, lo cual produce una destrucción de los puestos de trabajo. Sin embargo, es significativamente mayor el número de empleos que generan aquellas startups que sobreviven que el que destruyen las que terminan su actividad.<sup>37</sup>

### ***2.2.3. Productividad***

Las startups, antes de lanzar al mercado sus productos o servicios, investigan bien el mercado y prueban sus ideas innovadoras para validar su aceptación, es decir, ver si estas van a ser aceptadas y si realmente las personas están dispuestas a utilizar sus productos o comprar sus servicios. De esta manera ofrecen nuevas soluciones a las

---

<sup>33</sup> Kuckertz, A., Brändle, L., Gaudig, A., Hinderer, S., Reyes, C. A. M., Prochotta, A., ... & Berger, E. S. (2020). Startups in times of crisis—A rapid response to the COVID-19 pandemic. *Journal of Business Venturing Insights*, 169.

<sup>34</sup> Khan, Y. H. (2018). The Effectiveness of Entrepreneurial Activities for Economic Development: A Route to Innovation and Job Generation. *SocioEconomic Challenges*, 32-40

<sup>35</sup> Camarero García, Sebastián and Murmann, Martin (2020) “Unemployment Benefit Duration and Startup Success.” *ZEW-Centre for European Economic Research Discussion Paper*, 20-033.

<sup>36</sup> Bermejo, C., Megias, J., and Mitjavila M., (2019) “Spain Startup Manifesto: El Manifiesto Del Ecosistema Emprendedor.”

<sup>37</sup> Horrell, M., Litan, R.E. & Marion, E. (2010): After Inception: How Enduring is Job Creation by Startups?, *Kauffman Foundation Research Series: Firm Formation and Economic Growth*.

necesidades de los individuos a través de **procesos más efectivos** que aumentan la productividad y los ingresos.<sup>38</sup> Por ello, la creación de startups aumenta la productividad del trabajo, ya que **automatizan procesos y utilizan tecnologías** que les permiten hacer las mismas cosas a **menores costes**, o con **mayor alcance**.

#### **2.2.4. Competitividad**

Las startups, al invertir en capital humano, y especialmente en el de **jóvenes**, contribuyen a valorizar sus competencias, habilidades y desarrollo profesional. Esto prepara a los jóvenes a ser competitivos con las tendencias de los mercados actuales, al formarles en ecosistemas tecnológicos y **estimular su creatividad**.<sup>39</sup> No son solo los jóvenes los que adquieren nuevas competencias, sino también las empresas. Los mercados son muy competitivos y para entrar o mantenerse en ellos hace falta implementar estrategias innovativas. La dinámica del mercado requiere un **cambio constante**, la ventaja competitiva de una startup está determinada por la estrategia adoptada para diseñar su éxito en el futuro, así como los principios y prácticas que construirán y fortalecerán una cultura de la innovación basada en el diseño.<sup>40</sup> Esto es precisamente lo que hacen las startups, al **impulsar nichos de mercado** y aportar **ideas disruptivas en las industrias tradicionales**.

#### **2.2.5. P.I.B.**

Las startups que logran permanecer en el mercado contribuyen al aumento del PIB del país en el que operan. Las startups favorecen a los países con una baja renta per cápita ofreciendo **nuevas oportunidades laborales**, especialmente para los jóvenes, disminuyendo el desempleo y aumentando el nivel de vida de la sociedad al crecer los ingresos de los hogares. Esto estimula el crecimiento económico, aumentando así el PIB per cápita. En aquellos países cuya renta per cápita es alta, las startups al introducir nuevas tecnologías e integrar economías de escala facilitan a las empresas tradicionales que ya

---

<sup>38</sup> Sepulveda, M. (2017). (Obtenido de <https://pulsosocial.com>: <https://pulsosocial.com/2017/06/12/mejora-la-productividad-startup/> )

<sup>39</sup> Acs, Z., P. Arenius, M. Hay, and M. Minniti. 2005. 2004 Global Entrepreneurship Monitor. *London Business School and Babson College*.

<sup>40</sup> Fraser, H., (2012). *Design Works: How to Tackle Your Toughest Innovation Challenges Through*, University Toronto Press.

están establecidas satisfacer la creciente demanda de los mercados en crecimiento y la **expansión del país hacia nuevos mercados**.<sup>41</sup> Por tanto, podemos afirmar que existe una relación entre la actividad emprendedora de creación de startups por parte de un país con su PIB per cápita.

### 3. ALCANCE DEL PROYECTO

En el presente epígrafe se va a determinar el alcance del proyecto, planteando nuestra pregunta de investigación para ver si existe o no una determinada relación entre las variables, las hipótesis para plantear relaciones que luego comprobaremos de forma empírica y finalmente determinaremos las asunciones y restricciones con las que cuenta nuestro proyecto.

#### 3.1. Pregunta de investigación, objetivos e hipótesis

La **pregunta de investigación** que forma el eje central del trabajo, y que se utilizará para extraer las hipótesis es:

*“¿Tienen más éxito aquellas startups cuya actividad se desarrolla dentro de industrias consideradas modernas o aquellas enfocadas en sectores más tradicionales?”*

Para responder a esta pregunta se plantean los siguientes objetivos:

1. Conocer cómo afecta cada factor a la probabilidad de éxito de una startup. En este sentido contamos con la literatura bibliográfica y además con el modelo de Poisson.
2. Aprender cuáles son los factores que realmente influyen en el éxito de una startup. Para ello observaremos las diferentes variables consideradas en el modelo y su coeficiente de significación.

Tiene sentido que las startups enfocadas en industrias modernas, como el *Blockchain*, las *FinTechs*, la realidad virtual, etc. tengan más éxito que aquellas que desarrollan su actividad en industrias tradicionales, puesto que las segundas entran a un

---

<sup>41</sup> Acs, Z., P. Arenius, M. Hay, and M. Minniti. (2005). 2004 Global Entrepreneurship Monitor. *London Business School and Babson College*.



mercado en el que ya hay muchas empresas especializadas y posicionadas desde hace tiempo. En el caso de las startups de industrias modernas, estas cuentan con la ventaja de que los productos y servicios son nuevos en el mercado para todos, y no hay empresas que estén ya establecidas. Por ejemplo, para organizar un viaje puedes ir a la agencia de viajes de “El corte inglés” y que ellos te reserven el vuelo y el alojamiento, o puedes hacer todo esto tú mismo a través de internet, con plataformas como “Booking” o “Airbnb”. En este sentido, las personas más tecnológicas optarán por realizarlo ellos mismos a través de plataformas online, y las menos tecnológicas tendrán más tendencia a ir a una agencia de viajes tradicional como la de “El corte inglés”. Sin embargo, para invertir en criptomonedas, encontramos muchas más facilidades a través de startups que a través de sistemas tradicionales, y muchos bancos que lo han implementado como servicio lo han hecho a través de startups. Un ejemplo de esto es la startup española “Atani” que centraliza la gestión de este tipo de transacciones y ha levantado un total de 6 millones de euros de financiación hasta junio de 2021.<sup>42</sup> Por tanto, hemos considerado interesante analizar si realmente existe una diferencia en el éxito de las startups según su tipo de industria.

El **objetivo principal** de este trabajo es por tanto responder a nuestra pregunta de investigación y a los dos subobjetivos que plantea.

Como **objetivos secundarios** encontramos:

1. Comprobar la veracidad de mis hipótesis con exactitud, para lo cual trabajaremos con tres tipos de modelos diferentes; un modelo MCO, un modelo de Poisson y un modelo binomial negativo. Todos ellos realizados con el programa *Gretl*.
2. Aportar información relevante a la literatura existente, para así poder ayudar tanto a emprendedores como a inversores y gobiernos en la toma de decisiones relativas a las startups.

▪ **El modelo MCO:**

$$(\text{N}^\circ \text{ Rondas Financiación}) = \beta_0 + \beta_1 \text{tecnológica} + \beta_2 \text{Europa} + \beta_3 \text{Asia} + \beta_4 \text{Sudamérica} + \beta_5 \text{Oceania} + \beta_6 \text{Asia} + \beta_7 n^\circ \text{fundadores} + \beta_8 n^\circ \text{empleados} + \beta_9 \text{CB\_Rank} + \beta_{10} \text{total\_financiación} + U$$

<sup>42</sup> Chamizo, H., (2021). 10 startups españolas del sector de las criptomonedas que los expertos tienen en su radar en 2021, *Business Insider*, (disponible en: <https://www.businessinsider.es/startups-espanolas-criptomonedas-fondos-tienen-radar-932773> )

- **El modelo de Poisson:**

$$P(Y = y) = \frac{\lambda^y e^{-\lambda}}{y!}$$

$$\ln(\lambda_i) = \beta_0 + \beta_1 \text{tecnológica} + \beta_2 \text{Europa} + \beta_3 \text{Asia} + \beta_4 \text{Sudamérica} + \beta_5 \text{Oceanía} + \beta_6 \text{Asia} + \beta_7 n^\circ \text{fundadores} + \beta_8 n^\circ \text{empleados} + \beta_9 \text{CB\_Rank} + \beta_{10} \text{total\_financiación}$$

- **El modelo binomial negativo:**

$$p(Y) = \frac{\Gamma(Y + \alpha^{-1})}{\Gamma(Y + 1)\Gamma(\alpha^{-1})} \left( \frac{\alpha^{-1}}{\alpha^{-1} + \mu} \right)^{\alpha^{-1}} \left( \frac{\mu}{\alpha^{-1} + \mu} \right)^Y, \mu > 0, \alpha \geq 0$$

$$\log(\lambda) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k$$

Sobre estos modelos se plantean las siguientes **hipótesis de investigación:**

**H1:** Las startups cuya actividad se desenvuelve dentro de la industria tecnológica tienen más éxito que aquellas que se dedican a industrias tradicionales.

**H2:** Las startups que han sido fundadas por 3,4 o 5 personas tienen más éxito que las demás. ( $3 \leq B < 6$ )

**H3:** Las startups que han obtenido una mayor cantidad total de financiación han resultado más exitosas.

**H4:** Las startups de Norte América tienen más éxito que las de Europa, que a su vez tienen más éxito que las de Asia y así de la siguiente manera: Norte América > Europa > Asia > América del Sur > Oceanía > África.

### 3.2. Asunciones y restricciones

Para la realización del modelo se va a contar con las siguientes **asunciones:**

- El **éxito de las startups** se mide según el número de rondas de financiación conseguidas, ya que entendemos que las startups obtienen financiación en base a los beneficios estimados. Además, porque cada startup necesita una cantidad total de financiación diferente, dependiendo de los costes necesarios para operar y para mantenerse o expandirse en el mercado. Por lo tanto, entenderemos que cuántas más rondas de financiación obtenga una startup, mayor será su éxito.

- El **CB Rank** es el rango en el que clasifica “Crunchbase” el posicionamiento comparativo de las startups y está basado en un algoritmo de clasificación que tiene en cuenta algunas variables como la cantidad de conexiones que tiene un perfil, el nivel de participación de la comunidad, los eventos de financiación, los artículos de noticias y las adquisiciones.<sup>43</sup> A más bajo CB Rank, mejor posicionamiento comparativo.
- Los **startups** originarias de países de **Norteamérica tendrán más éxito**, pues este tipo de empresa emergente surgió en Silicon Valley, Estados Unidos, por lo que cuentan con una mayor experiencia y conocimiento de la metodología. Además, porque es una zona muy desarrollada tecnológicamente y en la que grandes empresas internacionales están asentadas.

Y cuento con estas **restricciones y medios**:

- Para hacer este trabajo se dispone de 150 horas de guía docente.
- La computadora utilizada es un ordenador Lenovo IdeaPad 530S Core i5 8th Gen.
- Se cuenta con acceso a la plataforma “Crunchbase”, la cual tiene una base datos con información acerca de distintas compañías, como sus inversores, fondos y noticias.
- Se cuenta con acceso a los programas Gretl y Orange.
- La veracidad de los datos obtenidos depende de la transparencia de las startups, de los documentos que están hayan facilitado a Crunchbase y de la actualización de los datos por parte de la propia plataforma.
- La muestra con la que se ha realizado la investigación es relativamente pequeña, de 257 startups.

---

<sup>43</sup>1 Million bot, (2019). 1MillionBot en Crunchbase la mayor base de datos del ecosistema startup, *Torre Juana*, (disponible en: <https://ost.torrejuana.es/1millionbot-ya-esta-en-crunchbase-la-mayor-base-de-datos-del-ecosistema-startup/#:~:text=El%20CB%20Rank%20esta%20basado,de%20noticias%20y%20las%20adquisiciones.> )

## 4. EL MODELO

### 4.1. Introducción

El mundo en el que vivimos está repleto de empresas y negocios, y las startups son un nuevo factor que ha entrado a operar en los mercados y está triunfando. Cada día se crean startups nuevas y es interesante investigar qué factores determinan su éxito. Las **startups** necesitan financiación constante para ir creciendo, y esta financiación se levanta a través de las conocidas “rondas de financiación”<sup>44</sup>. Si una startup realiza una ronda de financiación y no consigue el dinero que solicitaba (o gran parte de él), esta suele “morir”. Por lo tanto, con la realización de este trabajo se pretende aportar información acerca de qué factores se relacionan con la obtención de financiación por parte de las startups. Para ello, realizaremos un modelo econométrico en el que utilizaremos como variable dependiente el **número de rondas de financiación** obtenidas por la startup, ya que las cantidades monetarias son muy relativas y cada startup solicita las cantidades que en su caso concreto necesita.

### 4.2. Variables empleadas y forma de medida

- N.º de rondas de financiación: es la variable explicada, discreta y cuantitativa. Las startups obtienen financiación según sus beneficios esperados, por lo que se cree que aquellas que obtienen un mayor número de rondas de financiación tienen a su vez más éxito.
- CB Rank: es una variable explicativa, discreta y cuantitativa. Es el rango en el que la plataforma *Crunchbase* posiciona a la startup en comparación con las demás por lo que se considera que cuanto menor sea el número, mayor será el éxito de la startup.
- Industria: se trata de una variable explicativa, dicotómica. Toma el valor 1 para aquellas startups de la industria “moderna” y el valor 0 para aquellas otras de la industria tradicional. Nuestra hipótesis es que aquellas startups de la industria moderna tienen más éxito que el resto.
- Localización: variable explicativa, cualitativa. La hipótesis sobre esta variable es que las startups de Estados Unidos tienen más éxito que las de Europa que a su vez tienen más éxito que las del resto del mundo. Se han dividido las startups en 5 localizaciones:

---

<sup>44</sup> W. (2022, 24 febrero). *Cómo funcionan las rondas de financiación*. Lean Finance. <https://leanfinance.es/rondas-de-financiacion/>

Norte América, Europa, Asia, Sudamérica, Oceanía y África. Para poder meter esta variable en nuestro modelo se hará “one-hot-encoding”<sup>45</sup>, es decir, la convertiremos en tantas variables binarias como valores tiene. No obstante, de cara a no enfrentarnos a un problema de posible multicolinealidad, lo oportuno es seleccionar una de esas categorías como “base”, de modo que sea esa la que quede suprimida del modelo. Así, hemos seleccionado la categoría “Estados Unidos” como variable base y hemos convertido las variables en binarias, discretas.

- N.º de fundadores: variable explicativa, discreta y cuantitativa. Sobre esta variable recae la hipótesis de que aquellas startups fundadas por 2, 3 o 4 personas tienen más éxito que el resto.
- N.º de trabajadores: variable explicativa, discreta y cuantitativa. Se estima que cuántos más trabajadores tiene la startup, mayor es su éxito. Para la elaboración del modelo he tenido que hacer la media de los intervalos del número de empleados de cada startup.
- Cantidad total de financiación: variable explicativa, continua y cuantitativa. En este caso, a nuestro parecer existe una duda razonable sobre si que aquellas que obtienen más financiación son más exitosas, puesto que hay startups cuyos costes no son tan elevados, o que son capaces de autofinanciarse con sus propios ingresos. Como hay que decantarse por una u otra, se dirá que la hipótesis es que efectivamente si son más exitosas.

Se han **revisado los datos** meticulosamente para evitar arrastrar errores en el modelo. Antes de analizar las variables a través del modelo se considera conveniente calcular su media, mediana, desviación estándar, varianza de la muestra, curtosis, coeficiente de asimetría, mínimo, máximo y nivel de confianza.

---

<sup>45</sup> *One Hot Encoding | Interactive Chaos*. (2022). One Hot Encoding.  
<https://interactivechaos.com/es/manual/tutorial-de-machine-learning/one-hot-encoding>

Tabla 1: Análisis de variables

Variable	Media	Mediana	Desviación estándar	Varianza de la muestra	Curtosis	Coefficiente de asimetría	Mínimo	Máximo	Nivel de confianza(95%)
CB Rank	112946,11	61715	160448,21	25743627921,98	10,11	2,91	335	962665	19709,45
Industria	0,34	0	0,48	0,23	-1,57	0,67	0	1	0,06
Europa	0,23	0	0,42	0,18	-0,26	1,32	0	1	0,05
Asia	0,30	0	0,46	0,21	-1,27	0,86	0	1	0,06
Sudamérica	0,04	0	0,20	0,04	18,80	4,54	0	1	0,02
Oceania	0,02	0	0,15	0,02	38,63	6,35	0	1	0,02
África	0,02	0	0,15	0,02	38,63	6,35	0	1	0,02
Nº Fundadores	2,12	2	1,04	1,08	1	0,97	1	6	0,13
Nº Empleados	113,68	31	781,20	610271,26	131,55	11,32	6	10001	95,96
Nº Rondas financiación	2,41	2	2,63	6,93	5,12	2,06	0	15	0,32
Total financiación	40974313,67	1143831	224518292,75	50408463777993500	114,51	9,88	0	2935000000	27579811,41

Fuente: elaboración propia a través de Excel

Dentro de la tabla 1, de análisis de variables cabe destacar que la **media de fundadores** de una startup se encuentra en **2,2 personas**, y que a pesar de que algunas de las startups que componen el conjunto de datos nunca hayan recibido **financiación**, la **media** del conjunto se sitúa en **40 millones** de dólares obtenidos. El número máximo de rondas de financiación obtenidas ha sido de 15, y el mínimo de 0 como anteriormente mencionábamos. Otra cosa importante es que el **mínimo de empleados** que tienen estas startups es de **6 personas** y que dentro de la variable **CB Rank** las diferencias son muy grandes, ocupando el **mejor** puesto la startup situada en el número **335**, y el **“peor”** la situada en el **962.665**.

También se puede observar el **coeficiente de asimetría**, que permite comparar las dispersiones de dos distribuciones distintas, siempre que sus medias sean positivas. La menor dispersión corresponderá al valor del coeficiente de asimetría menor, que en el caso del presente estudio es la **industria**, implicando esto que el hecho de que la startup sea tecnológica o no, **no afecta mucho a la variable explicada**, que es el número de rondas de financiación, por lo que nuestra hipótesis de que las startups tecnológicas tienen más éxito que las tradicionales sería rechazada. Además podemos observar también que nuestra variable dependiente **número de rondas de financiación** tiene un coeficiente de variación muy alto, de **2,06**, muy superior a 0,5. Por lo tanto vemos como la variable dependiente está **muy influida por el resto de las variables del modelo**, lo que nos llevará a aplicar una regresión de Poisson posteriormente para el correcto análisis del modelo.

A continuación se procederá a determinar si ha surgido un problema de **multicolinealidad**, pues aunque se haya transformado la variable localización en tantas variables binarias como valores tenía la variable, es necesario analizar las correlaciones

existentes entre las diferentes variables explicativas del modelo. La multicolinealidad es la relación de dependencia lineal fuerte entre dos o más variables independientes en una regresión múltiple<sup>46</sup>. Existen distintos tipos de multicolinealidad, esta puede ser **perfecta** si el coeficiente es **1**, **imperfecta grave** si es **superior a 0,80**, e **imperfecta** cuando sea **inferior a 0,80**. Sería preocupante por tanto que se de alguno de estos tipos, pues implicaría una alta correlación entre las variables. La correlación significa que dos cosas suceden a la vez, pero no supone causalidad (que exista una relación causa efecto).

Tabla 2: Análisis de correlaciones entre variables

Variables	Asia	Sudamérica	Oceanía	África	Nº Fundadores	Nfundadores_ tipificado	Nº Empleados	Nempleados_ tipificado	NºRondas financiación	Total financiación
Asia	1									
Sudamérica	-0,139588479	1								
Oceanía	-0,102060937	-0,032693962	1							
África	-0,102060937	-0,032693962	-0,023904382	1						
Nº Fundadores	-0,079311729	0,01169278	0,031153729	-0,043441069	1					
Nfundadores_ tipificado	-0,079311729	0,01169278	0,031153729	-0,043441069	1	1				
Nº Empleados	0,158800166	-0,01847779	-0,018972423	-0,015832664	-0,015090227	-0,015090227	1			
Nempleados_ tipificado	0,158800166	-0,01847779	-0,018972423	-0,015832664	-0,015090227	-0,015090227	1	1		
NºRondas financiación	-0,006993309	0,164346327	-0,073305611	-0,092919919	0,171192438	0,171192438	0,229870021	0,229870021	1	
Total financiación	0,188345087	-0,030959113	-0,021049744	-0,027517011	-0,017139583	-0,017139583	0,869910224	0,869910224	0,350712822	1

Fuente: elaboración propia a través de Excel

Como se puede observar en la tabla 2, de análisis de correlaciones entre variables, existen **2 correlaciones perfectas**, cuyo coeficiente es 1, entre la variable número de fundadores y número de fundadores tipificado, y otra entre las variables número de empleados y número de empleados tipificado. Esto se debe a que se trata de la **misma variable**, pero esta **se ha escalado** para el correcto análisis del posterior modelo. De todas formas, la variable no tipificada no se incluirá en dicho modelo.

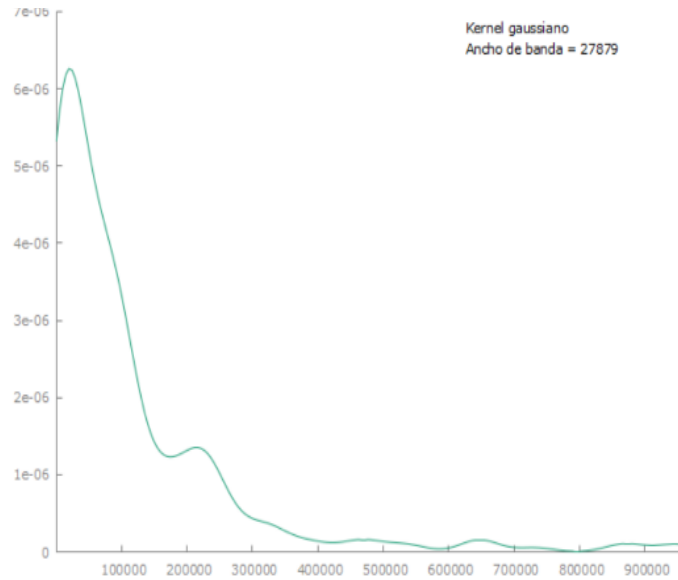
Por otro lado, también quedan reflejadas en la tabla otras **correlaciones imperfectas graves**, la primera entre las variables número de empleados y total financiación, y la misma variable tipificada y el total de financiación. Esto realmente tiene mucho sentido, pues es lógico que, **a mayor financiación, mayor sea el número de empleados** que la startup puede mantener. El resto de los resultados de la tabla nos indican la falta de multicolinealidad entre las variables, y además se puede observar que como muchas variables tienen una correlación muy cercana a 0, la falta de correlación entre las variables impera en el modelo.

<sup>46</sup> Rodó, P. (2021, 19 febrero). *Multicolinealidad*. Economipedia.

<https://economipedia.com/definiciones/multicolinealidad.html#:~:text=La%20multicolinealidad%20es%20la%20relaci%C3%B3n,m%C3%A1s%20de%20dos%20variables%20explicativas.>

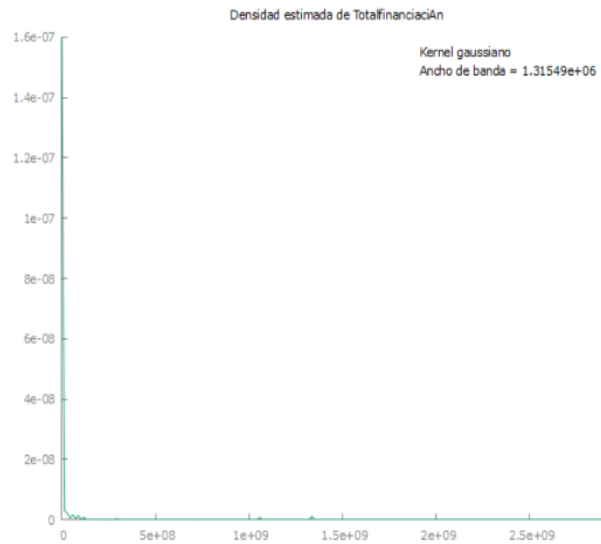
Otro de los análisis que se va a practicar sobre las variables consiste en ver su **densidad estimada**, lo que nos es útil para ver su asimetría.

*Gráfico 1: Densidad Estimada de CBRank*



*Fuente: elaboración propia a través de Gretl*

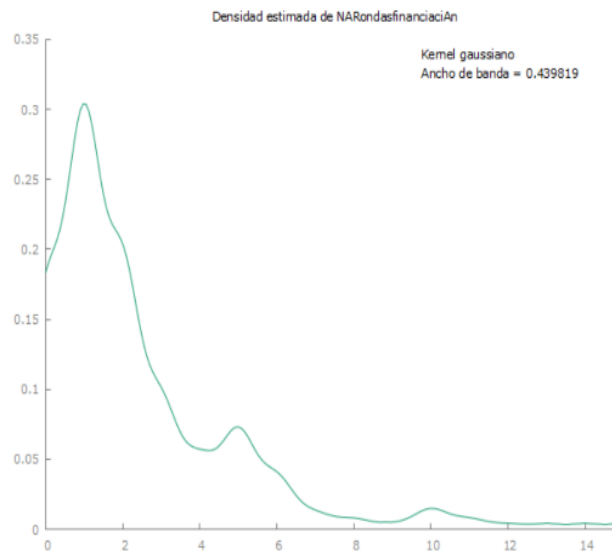
*Gráfico 2: Densidad estimada de Total Financiación*



*Fuente: elaboración propia a través de Gretl*



*Gráfico 3: Densidad estimada de NARondas de Financiación*



*Fuente: elaboración propia a través de Gretl*

En los gráficos 1,2, y 3 se ve como la **densidad de las variables rondas financiación, financiación total y CB Rank es asimétrica a la derecha**. Luego habría que poner un logaritmo a esta variable si se quiere predecir (+1, ya que el logaritmo de 0 no está definido) para que esta salga más centrada. Por lo tanto, a partir de este momento, se trabajará con la transformación de estas variables en logaritmos neperianos.

#### **4.3. Estimación del modelo**

Dado que la **variable dependiente** es el número de rondas de financiación, y esta es una **variable de cuenta** (pues está contando el número de veces que se ha dado un suceso determinado, en este caso el número de rondas de financiación; 1 ronda, 2 rondas, 3 rondas, etc., el modelo a seguir adecuado es un modelo de cuenta). También podríamos utilizar el de Mínimos Cuadrados Ordinarios (en adelante “**MCO**”), sin embargo, un modelo de cuenta nos va a proporcionar resultados más precisos.

Los modelos de cuenta se encuentran dentro de la categoría de **modelos lineales generalizados** (en adelante “**MLG**”). Los MLG<sup>47</sup> son aquellos en los que la variable

---

<sup>47</sup> *Modelos lineales generalizados*. (2021). Modelos Lineales Generalizados. <https://www.ibm.com/docs/es/spss-statistics/SaaS?topic=statistics-generalized-linear-models>

dependiente tiene una relación lineal con los factores y covariables, por lo que no tiene una distribución normal y utiliza una función de enlace para encontrar los estimadores. Dentro de los MLG están los modelos de cuenta, entre los que a su vez tenemos 2 posibilidades; el modelo binomial negativo y el modelo de Poisson. El **modelo de Poisson** se utilizará en el caso de que se suponga que no hay efecto contagio, lo que significaría en este caso que el hecho de que una startup haya obtenido 7 rondas de financiación no hace más probable que obtenga una octava. Se empleará el **modelo binomial negativo** si se sospecha que hay efecto contagio, es decir, que cuántas más rondas de financiación obtenga la startup, más probabilidades tendrá de tener nuevas rondas. Como a priori no se sabe muy bien cuál de los dos modelos nos podría encajar, vamos a probar los dos a ver cuál nos proporciona un mejor ajuste. Y además probaremos también con un MCO para ver la precisión de los datos obtenidos.

#### ***4.3.1. Modelo binomial negativo:***

Se ha creado el modelo especificando que nuestra variable dependiente es el **número de rondas de financiación** y establecemos como variables independientes al resto; industria, las 5 variables de localización, número de fundadores y número de empleados. En este caso y en el siguiente, al ser los modelos binomial negativo y de Poisson modelos de cuenta, la variable dependiente número de rondas de financiación, no la utilizaremos transformada en logaritmo neperiano, pues tiene que tomar valores enteros.

Marcados con asteriscos obtenemos las variables significativas;

- Un asterisco (\*) significa que la variable es **significativa al 10%** para un  $\alpha$  del 0,1.
- Dos asteriscos (\*\*) significan que la variable es **significativa al 5%** con un  $\alpha$  del 0,05 (p valor inferior a 0,05).
- Tres asteriscos (\*\*\*) significan que la variable es **significativa al 1%** (p valor inferior a 0,01).

*Tabla 3: Modelo Binomial Negativo*

Se alcanzó la convergencia después de 6 iteraciones

Modelo 2: Binomial negativa, usando las observaciones 1-257

Variable dependiente: NARondasfinanciación

Desviaciones típicas basadas en el Hessiano

	coeficiente	Desv. típica	z	valor p	
const	-0.585003	0.615440	-0.9505	0.3418	
LogCBRank	-0.103591	0.0371943	-2.785	0.0054	***
Industria	0.00490646	0.0999996	0.04906	0.9609	
Europa	0.0958413	0.125431	0.7641	0.4448	
Asia	-0.149176	0.116383	-1.282	0.1999	
Sudamérica	0.556671	0.189585	2.936	0.0033	***
Oceanía	-0.663702	0.411261	-1.614	0.1066	
África	-0.471886	0.479069	-0.9850	0.3246	
Nfundadores_tipi~	-0.0331630	0.0462352	-0.7173	0.4732	
Nempleados_tipif~	-0.0172309	0.0332024	-0.5190	0.6038	
LogFinanciaciónT~	0.175170	0.0208677	8.394	4.69e-017	***
alpha	0.0896890	0.0369363	2.428	0.0152	**
Media de la vble. dep.	2.412451	D.T. de la vble. dep.	2.632638		
Suma de cuad. residuos	900.3511	D.T. de la regresión	1.913103		
Chi-cuadrado(10)	205.6388	valor p	1.07e-38		
Log-verosimilitud	-405.2195	Criterio de Akaike	834.4390		
Criterio de Schwarz	877.0279	Crit. de Hannan-Quinn	851.5661		

*Fuente: elaboración propia a través de Gretl*

Como se puede observar en la tabla, nos sale que las variables **Sudamérica**, **CB Rank** y **Total financiación** son especialmente significativas. Es importante mirar también el contraste de significación global, que es que el **p valor** es de **1.07e<sup>-38</sup>**. Esto dice que **el modelo es significativo en su conjunto** pues es inferior a 0,01. A continuación se va a probar con un modelo de Poisson a ver si se obtiene un mejor resultado.

### 4.3.2. Modelo de Poisson

Tabla 4: Modelo de Poisson

Se alcanzó la convergencia después de 6 iteraciones

Modelo 1: Poisson, usando las observaciones 1-257  
Variable dependiente: NARondasfinanciación  
Desviaciones típicas basadas en el Hessiano

	coeficiente	Desv. típica	z	valor p	
const	-0.500163	0.547068	-0.9143	0.3606	
LogCBRank	-0.106786	0.0321412	-3.322	0.0009	***
Industria	0.00448158	0.0882167	0.05080	0.9595	
Europa	0.0960302	0.110002	0.8730	0.3827	
Asia	-0.125278	0.101568	-1.233	0.2174	
Sudamérica	0.547825	0.157397	3.481	0.0005	***
Oceanía	-0.672745	0.383726	-1.753	0.0796	*
África	-0.469493	0.453978	-1.034	0.3011	
Nfundadores_típico	-0.0385134	0.0400135	-0.9625	0.3358	
Nempleados_típico	-0.0164670	0.0259294	-0.6351	0.5254	
LogFinanciaciónT	0.171113	0.0189556	9.027	1.76e-019	***
Media de la vble. dep.	2.412451	D.T. de la vble. dep.	2.632638		
Suma de cuad. residuos	894.7580	D.T. de la regresión	1.907152		
R-cuadrado de McFadden	0.317190	R-cuadrado corregido	0.298868		
Chi-cuadrado(10)	262.2980	valor p	1.40e-50		
Log-verosimilitud	-409.9378	Criterio de Akaike	841.8755		
Criterio de Schwarz	880.9154	Crit. de Hannan-Quinn	857.5754		

Contraste de sobredispersión: Chi-cuadrado(1) = 5.81799 [0.0159]

Fuente: elaboración propia a través de Gretl

Se puede observar que, como era de esperar, las variables que son significativas en el modelo binomial negativo también son las que me salen significativas en el modelo de Poisson. Es decir, **las variables significativas no han cambiado**, pero si han cambiado dos cosas importantes; la primera es que ahora la variable Oceanía también es significativa al 10%, pues su p valor es de 0,0796, que es inferior a 0,1. La segunda cuestión que ha cambiado es que el **contraste de significación global tiene un valor muchísimo más bajo**, de  $1.40e^{-50}$  lo que me está diciendo que este modelo es mejor que el anterior. En conclusión, el modelo de Poisson es de una calidad mayor.

### 4.3.3. Modelo MCO

Por último, se realizará un modelo de **Mínimos Cuadrados Ordinarios (MCO)** pues, aunque para el análisis este modelo sea menos preciso, se puede obtener información interesante. Este consiste en un **método de estimación** en el que los estimadores MCO de los parámetros  $\beta$  del modelo son aquellos que hacen mínima la suma de los cuadrados de los residuos. En este caso, el modelo MCO no es un modelo de cuenta, por lo que se utilizará la variable dependiente número de rondas de financiación transformada a logaritmo neperiano:

Tabla 5: Modelo MCO

Modelo 3: MCO, usando las observaciones 1-257  
Variable dependiente: LogRondas

	coeficiente	Desv. típica	Estadístico t	valor p	
const	1.34828	0.266410	5.061	8.17e-07	***
LogCBRank	-0.107234	0.0202194	-5.304	2.53e-07	***
Industria	-0.0237407	0.0512527	-0.4632	0.6436	
Europa	0.0664081	0.0646438	1.027	0.3053	
Asia	-0.0440045	0.0591781	-0.7436	0.4578	
Sudamérica	0.278296	0.122621	2.270	0.0241	**
Oceanía	-0.283927	0.162216	-1.750	0.0813	*
frica	-0.135650	0.163089	-0.8318	0.4064	
Nfundadores_tipi~	0.00673699	0.0255423	0.2638	0.7922	
Nempleados_tipif~	0.0310878	0.0250769	1.240	0.2163	
LogFinanciación~	0.0654370	0.00546947	11.96	2.65e-026	***
Media de la vble. dep.	0.994424	D.T. de la vble. dep.	0.669261		
Suma de cuad. residuos	36.47339	D.T. de la regresión	0.385053		
R-cuadrado	0.681914	R-cuadrado corregido	0.668984		
F(10, 246)	52.73757	Valor p (de F)	1.47e-55		
Log-verosimilitud	-113.7718	Criterio de Akaike	249.5437		
Criterio de Schwarz	288.5835	Crit. de Hannan-Quinn	265.2436		

Sin considerar la constante, el valor p más alto fue el de la variable 10 (Nfundadores\_tipificado)

Fuente: elaboración propia a través de Gretl

En la tabla se observa como el modelo, aunque es muy débil, es significativo pues el p valor es casi 0. Además, aparecen como variables muy significativas tanto el CB Rank como el total de financiación. Sin embargo, el R<sup>2</sup> corregido es 0.6689 que no es muy alto, aunque lo se podría intentar mejorar con *Machine Learning*. Esto se debe a que la precisión de estos modelos es mucho mayor, al utilizar redes neuronales para mejorar sus propios resultados.

Por lo tanto, como conclusiones se podría decir que:

- Respecto de la **validez global**, el mejor modelo es el de **MCO**, ya que cuenta con un el **p valor más bajo**, siendo este de  $1.47e^{-55}$ , comparado con el del modelo binomial negativo de  $1.07e^{-38}$ , y el Poisson de  $1.40e^{-50}$ .
- Respecto de la **relevancia de las variables** se puede afirmar que estas tienen una **mayor significación con el modelo de Poisson**, en el que encontramos las variables Sudamérica, CB Rank y financiación total con una relevancia del 1%, además de un nivel de significación del 10% en la variable Oceanía, frente a los otros modelos que presentaban; o bien el binomial negativo con las mismas tres variables a una relevancia del 1%, pero sin ser significativa en este caso la variable Oceanía, o bien el de MCO con 2 variables con un nivel de significación del 1%, es decir, una menos que en los otros 2 modelos.

- Finalmente se ha elegido el modelo de Poisson, al ser este un modelo de cuenta apropiado para nuestra variable dependiente número de rondas de financiación y tener este una mayor significación global que el modelo binomial negativo, y al tener variables más significativas que el modelo MCO.


#### 4.4. Análisis del modelo

Una vez se ha determinado que se utilizará el modelo de Poisson, se analizarán las **características de nuestro modelo a través del modelo MCO:**

-En primera instancia, decir que el modelo **parece lineal** pues partiendo de la hipótesis nula de que la relación es lineal nos sale un estadístico de contraste LM= 57.116 con valor  $p = P(\text{Chi-cuadrado}(3) > 57.116) = 2.42746e-12$ .

-En segundo lugar, se analiza la **normalidad de los residuos**, ahora la hipótesis nula es que el error tiene una distribución normal y el estadístico de contraste obtendría un Chi cuadrado (2) = 25.6474 con valor  $p = 2.6961e-06$ . Por lo tanto, se puede afirmar que hay normalidad en los residuos.

*Gráfico 4: Estadístico para el contraste de normalidad*



*Fuente: elaboración propia a través de Gretl*

- Finalmente se analiza la heterocedasticidad del modelo a través del contraste de **heterocedasticidad de White**, partiendo de la hipótesis nula de que no hay heterocedasticidad. Se obtiene el resultado del estadístico de contraste que es: LM

= 99.3468 con un valor  $p = P(\text{Chi-cuadrado}(29) > 99.3468) = 1.2442e-09$ . No hay heterocedasticidad.

#### 4.5. Interpretación de las variables

Para la interpretación de las variables se utilizará el modelo de Poisson, al ser este el modelo elegido para el estudio tanto por su significación global como por la significación individual de sus variables.

*Tabla 6: Modelo de Poisson*

Se alcanzó la convergencia después de 6 iteraciones

Modelo 1: Poisson, usando las observaciones 1-257  
Variable dependiente: NARondasfinanciación  
Desviaciones típicas basadas en el Hessiano

	coeficiente	Desv. típica	z	valor p	
const	-0.500163	0.547068	-0.9143	0.3606	
LogCBRank	-0.106786	0.0321412	-3.322	0.0009	***
Industria	0.00448158	0.0882167	0.05080	0.9595	
Europa	0.0960302	0.110002	0.8730	0.3827	
Asia	-0.125278	0.101568	-1.233	0.2174	
Sudamérica	0.547825	0.157397	3.481	0.0005	***
Oceanía	-0.672745	0.383726	-1.753	0.0796	*
África	-0.469493	0.453978	-1.034	0.3011	
Número de fundadores	-0.0385134	0.0400135	-0.9625	0.3358	
Número de empleados	-0.0164670	0.0259294	-0.6351	0.5254	
LogFinanciación	0.171113	0.0189556	9.027	1.76e-019	***
Media de la vble. dep.	2.412451	D.T. de la vble. dep.	2.632638		
Suma de cuad. residuos	894.7580	D.T. de la regresión	1.907152		
R-cuadrado de McFadden	0.317190	R-cuadrado corregido	0.298868		
Chi-cuadrado(10)	262.2980	valor p	1.40e-50		
Log-verosimilitud	-409.9378	Criterio de Akaike	841.8755		
Criterio de Schwarz	880.9154	Crit. de Hannan-Quinn	857.5754		

Contraste de sobredispersión: Chi-cuadrado(1) = 5.81799 [0.0159]

*Fuente: elaboración propia a través de Gretl*

La gráfica muestra los resultados del modelo de Poisson realizado con Gretl, del cual se pueden esgrimir las siguientes conclusiones:

- Variables **no significativas**: las variables **Europa** (p valor = 0,3827), **Asia** (p valor = 0,2174), **África** (p valor = 0,3011), **número de fundadores** (p valor = 0,3358), **número de empleados** (p valor = 0,5254) e **industria** (0,9595) no son significativas puesto que su p valor es superior a 0,1. Esto significa que no influyen en la cantidad de rondas de financiación que obtiene una startup.
- Variables **significativas con  $\alpha = 0,1$** : las variable **Oceanía** tiene una significación del 10%, por lo que influye en la cantidad de rondas de financiación obtenidas por una startup, pero es una influencia débil.

- Variables **significativas con  $\alpha = 0,05$** : no contamos con este tipo de variables en este modelo.
- Variables **especialmente significativas con  $\alpha = 0,01$** : las variables **CB Rank** (p valor = 0,0009), **Sudamérica** (p valor = 0,0005) y **Financiación total** (p valor = 1,76e-019) tienen un p valor muy cercano a 0, lo que muestra su significación y relevancia para el modelo.

Por otro lado, es de mencionar el **R cuadrado de McFadden**. Este no tiene interpretación, simplemente es una métrica de bondad de ajuste, no es el porcentaje de la variabilidad explicada como sucedía con el r cuadrado en un modelo de Mínimos Cuadrados Ordinarios. El  $R^2$  muestra la bondad del ajuste, cuanto más se acerque a 1, más se aproximará el modelo a la realidad. El  $R^2$  que hemos obtenido es **0,3171**. El valor está muy distante de ser 1 y por tanto muestra que el modelo no se aproxima mucho a la realidad. Aun así, dada la complejidad del modelo y la significación de contraste global se puede interpretar que es un “buen” modelo y por tanto trabajaremos con él. Es posible que, aplicando otro tipo de herramientas como el *machine learning*, se consiga un modelo con un  $R^2$  mayor. Por su parte se ha obtenido un **contraste de significación global de 1,40e-50** que demuestra que a pesar de que el  $R^2$  obtenido no sea muy cercano a 1, el modelo es significativo y por tanto válido.

A pesar de que **la variable industria** no salía significativa, se quiere analizar en profundidad si esta variable es realmente significativa o no, debido a que es la variable sobre la que se constituye el eje de nuestro trabajo. Para ello se va a hacer un **test de contraste de modelos** analizando el  $R^2$  del modelo MCO con una restricción del modelo sin la industria. De esta manera, si el  $R^2$  del modelo es equivalente al obtenido en el apartado anterior en el que se había realizado un modelo MCO para compararlo con el modelo de Poisson y el binomial negativo, significaría que la industria no es significativa.



Tabla 7: Modelo MCO sin la variable industria

Modelo 4: MCO, usando las observaciones 1-257  
Variable dependiente: LogRondas


	coeficiente	Desv. típica	Estadístico t	valor p	
const	1.34339	0.265778	5.055	8.40e-07	***
LogCBRank	-0.107317	0.0201864	-5.316	2.37e-07	***
Europa	0.0644557	0.0644036	1.001	0.3179	
Asia	-0.0448837	0.0590535	-0.7601	0.4479	
Sudamérica	0.276988	0.122393	2.263	0.0245	**
Oceanía	-0.280772	0.161815	-1.735	0.0840	*
África	-0.140503	0.162493	-0.8647	0.3881	
Nfundadores_tipi~	0.00715319	0.0254859	0.2807	0.7792	
Nempleados_tipif~	0.0300093	0.0249288	1.204	0.2298	
LogFinanciaciónI~	0.0653080	0.00545369	11.98	2.32e-026	***
Media de la vble. dep.	0.994424	D.T. de la vble. dep.	0.669261		
Suma de cuad. residuos	36.50520	D.T. de la regresión	0.384440		
R-cuadrado	0.681637	R-cuadrado corregido	0.670036		
F(9, 247)	58.76031	Valor p (de F)	2.07e-56		
Log-verosimilitud	-113.8839	Criterio de Akaike	247.7677		
Criterio de Schwarz	283.2585	Crit. de Hannan-Quinn	262.0404		

Sin considerar la constante, el valor p más alto fue el de la variable 10 (Nfundadores\_tipificado)

Fuente: elaboración propia a través de Gretl

Se puede ver que **el R<sup>2</sup> corregido es prácticamente igual**. En el modelo MCO en el que la variable industria estaba incluida era de 0.6689, mientras que el que se ha obtenido en la tabla, que no incluye la variable industria, es de 0.6700. Es decir, solo ha caído 0.0011. Este contraste tan bajo indica que el R<sup>2</sup> del modelo no ha variado casi nada, por lo que la variable industria no es significativa. De todas formas, para descartar del todo la significación de esta variable, se realizará un análisis de datos simple a través de un *Scatterplot*.

Gráfico 5: Scatterplot Industria



Fuente: elaboración propia a través de Gretl

Como se puede observar en el gráfico 5, **no existe ninguna relación entre ambas variables**, ni lineal ni cuadrática, por lo que las variables no están asociadas. Definitivamente se puede descartar la significación de la variable industria en nuestro modelo.

#### 4.6. Multicolinealidad

Anteriormente se había repasado lo que implicaba que un modelo estuviera conformado por variables entre las que existiese multicolinealidad. Ahora se procederá a analizar dicha multicolinealidad entre variables de una manera diferente. Se **examinarán los factores de inflación de la varianza** que sirven para ver que no exista multicolinealidad entre las variables a través de un indicador denominado “*Variance Inflation Factor*” (**VIF**). En el caso de que alguno de ellos esté por encima de 10 significaría que existe problema de multicolinealidad imperfecta grave y el modelo no sería válido.

*Tabla 8: Análisis VIF*

```
Factores de inflación de varianza (VIF)
Mínimo valor posible = 1.0
Valores mayores que 10.0 pueden indicar un problema de colinealidad
```

Industria	1.022
Europa	1.253
Asia	1.279
Sudamérica	1.066
Oceanía	1.040
África	1.041
Nfundadores_tipificado	1.023
Nempleados_tipificado	1.037

VIF(j) = 1/(1 - R(j)^2), donde R(j) es el coeficiente de correlación múltiple entre la variable j y las demás variables independientes


*Fuente: elaboración propia a través de Gretl*

En este caso se puede observar en la tabla de análisis VIF como no se han encontrado problemas de multicolinealidad, ya que todos los VIF se encuentran muy por debajo de 10, por lo que no tenemos por qué preocuparnos y el modelo está bien.

## 4.7. Predicción

En este apartado se elaborarán las predicciones del modelo seleccionado como el óptimo, es decir, el de Poisson.

*Gráfico 6: Predicción*



*Fuente: elaboración propia a través de Gretl*

La gráfica muestra que **las proyecciones se ajustan muy bien al modelo**, exceptuando aquellos casos en los que las startups llegan a 12 o más rondas de financiación, que en ellos no se ajusta tan bien. Se puede apreciar como la línea verde que representa el número de rondas de financiación de los datos al llegar a 12 o más rondas no sigue acompañada por la línea naranja que representa la predicción.

## 5. RESULTADOS DEL ESTUDIO

Una vez analizado el modelo se intentará corroborar que las hipótesis de investigación que habíamos planteado se cumplen.

**H1:** Las startups cuya actividad se desenvuelve dentro de la industria tecnológica tienen más éxito que aquellas que se dedican a industrias tradicionales. En este caso la hipótesis **no se cumple**, pues como se puede analizar en la tabla 4, la variable industria no es significativa (p valor de 0,9595). Además, se han contrastado dos modelos MCO, uno teniendo en cuenta esta variable y otro sin ella, para descartar su significación y efectivamente la significación global del modelo apenas variaba.

**H2:** Las startups que han sido fundadas por 3,4 o 5 personas tienen más éxito que las demás. ( $3 \leq B4 < 6$ ). En este caso **tampoco se ha podido validar** nuestra hipótesis, pues la variable **número de fundadores** tiene un p valor de 0,3358 en el modelo de Poisson.

**H3:** Las startups que han obtenido una mayor cantidad total de financiación han resultado más exitosas. Se puede afirmar por tanto que nuestra hipótesis **se cumple**, pues la variable **financiación total** tiene un p valor de  $1,76e-019$ , que es muy cercano a 0, lo que demuestra la relevancia de la variable para nuestro modelo. Esto es lógico, pues es normal que cuantas más rondas de financiación obtenga la startup, más financiación recibirá.

**H4:** Las startups de Norte América tienen más éxito que las de Europa, que a su vez tienen más éxito que las de Asia y así de la siguiente manera: Norte América > Europa > Asia > América del Sur > Oceanía > África. El modelo de Poisson muestra que **este orden** que se había planteado en nuestra hipótesis **no se cumple**, y que, de hecho, a la hora de obtener financiación, la variable cuyo p valor más se acerca a cero y por tanto es más exitosa es la de Sudamérica (p valor = 0,0005), seguida por Oceanía (p valor = 0,0796), a la que le sigue Asia (p valor = 0,2174), luego África (p valor = 0,3011) y finalmente Europa (p valor = 0,3827). Por lo tanto, el orden quedaría así: **América del Sur > Oceanía > Asia > África > Europa**.

## 6. MACHINE LEARNING

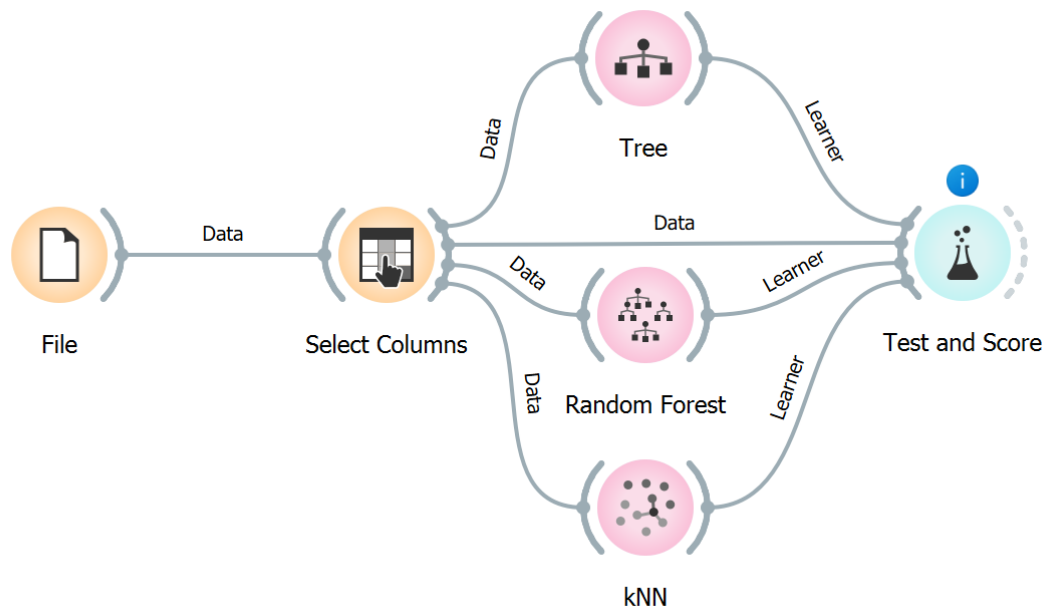
Recurrimos al Machine Learning para aportar evidencia empírica a favor de las hipótesis al carecer de la evidencia analítica de los modelos econométricos. Por ello se realizará un pequeño modelo predictivo de **Machine Learning sencillo**, en concreto al *Decision Tree*, *Random Forest* y *Knn*, los cuales explicaremos a continuación. El *Machine Learning* es “una disciplina del campo de la Inteligencia Artificial que, a través de algoritmos, dota a los ordenadores de la capacidad de identificar patrones en datos masivos y elaborar predicciones (análisis predictivo).”<sup>48</sup> En nuestro caso utilizaremos el *Machine Learning* de aprendizaje supervisado, pues los algoritmos contarán con un

---

<sup>48</sup>Iberdrola, Qué es el machine learning, (disponible en: [https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatizado#:~:text=El%20Machine%20Learning%20es%20una,elaborar%20predicciones%20\(an%C3%A1lisis%20predictivo\)](https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatizado#:~:text=El%20Machine%20Learning%20es%20una,elaborar%20predicciones%20(an%C3%A1lisis%20predictivo))).

aprendizaje previo basado en un sistema de etiquetas que asociadas a los datos permiten tomar decisiones o realizar predicciones.

*Ilustración 1: Orange Testing Process*



*Fuente: elaboración propia a través de Orange*

Como se puede observar en la “*Ilustración 1: Orange Testing Process*”, metiendo nuestros **datos de 152 startups** en el programa Orange y seleccionando las columnas que nos interesaban, que son, dentro de la clasificación “**features**” **las variables numéricas**: “Total Financiación”, “Nempleados\_tipificado”, “Nfundadores\_tipificado”, “Log CB Rank” y “Log Financiación Total”. Por otro lado, dentro también de la clasificación “features” se encuentran **las variables categóricas**: Industria, Europa, Asia, Sudamérica, Oceanía y África. Y, por último, estableciendo como “**target**” la variable “Log Rondas”, se ha podido obtener unos resultados de su *kNN*, *Random Forest* y *Decision Tree*.

En primer lugar, se ha realizado un **Decisión Tree**, es decir, un diagrama en forma de árbol creado a partir del Machine Learning a través del programa Orange. Es preciso

comprender que “un árbol de decisión es un mapa de los posibles resultados de una serie de decisiones relacionadas.”<sup>49</sup>

A continuación, se elaborará el *Random Forest*, puesto que los árboles de decisión tienden a sobre ajustar el modelo, es decir, a aprender bien los datos de entrenamiento, pero luego la generalización es peor. Para enmendar esta generalización se debe emplear la regulación, que consiste en la combinación de varios árboles. Por lo tanto, el *Random Forest* es “un conjunto de árboles de decisión combinados con bagging (los algoritmos simples se usan en paralelo). Al usar bagging, lo que en realidad está pasando, es que distintos árboles ven distintas porciones de los datos. Ningún árbol ve todos los datos de entrenamiento. Esto hace que cada árbol se entrene con distintas muestras de datos para un mismo problema. De esta forma, al combinar sus resultados, unos errores se compensan con otros y tenemos una predicción que generaliza mejor.”<sup>50</sup>

En tercer y último lugar se utilizará un *kNN*, *k Nearest Neighbours*, que es “*KNN is a model that classifies data points based on the points that are most similar to it. It uses test data to make an “educated guess” on what an unclassified point should be classified as KNN is often used in simple recommendation systems, image recognition technology, and decision-making models.*”<sup>51</sup> En este sentido, lo que realmente realiza este algoritmo es clasificar cada dato nuevo en un grupo dependiendo del número (k) de vecinos que tenga más cerca. Es decir, “calcula la distancia del elemento nuevo a cada uno de los existentes, y ordena dichas distancias de menor a mayor para ir seleccionando el grupo al que pertenecer. Este grupo será, por tanto, el de mayor frecuencia con menores distancias.”<sup>52</sup>

---

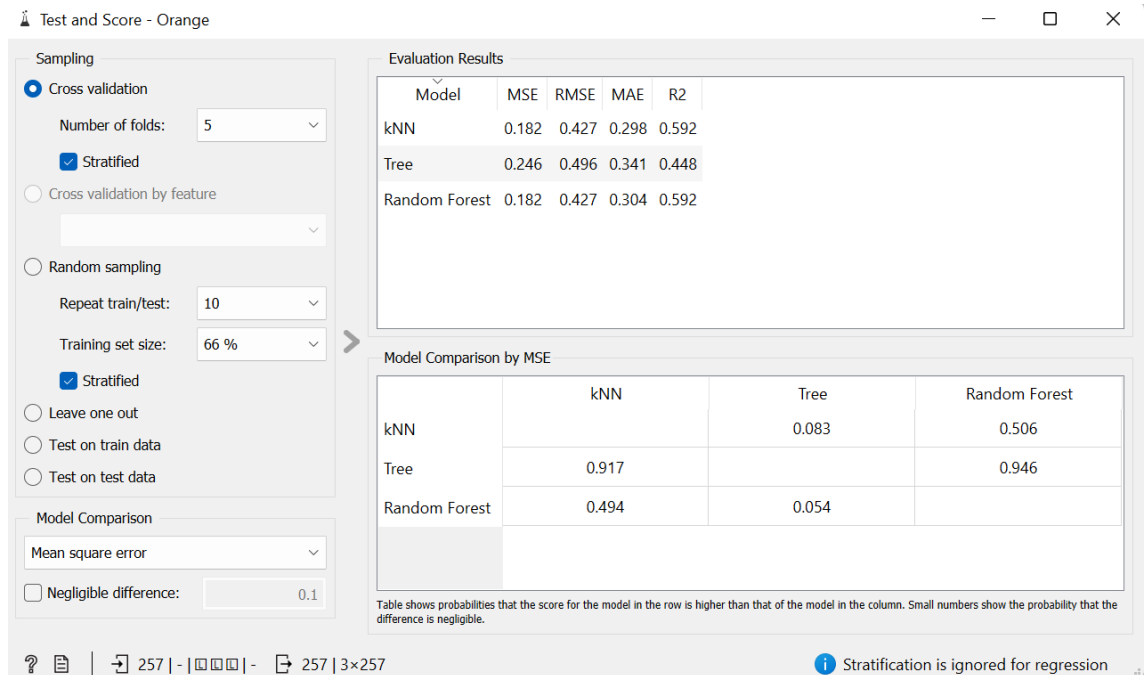
<sup>49</sup>Lucidchart, ¿Qué es un diagrama de árboles de decisión? (disponible en: <https://www.lucidchart.com/pages/es/que-es-un-diagrama-de-arbol-de-decision> )

<sup>50</sup>Martínez, J., (2020). Random Forest (Bosque Aleatorio): combinando árboles, *IArtificial* (disponible en: <https://www.iartificial.net/random-forest-bosque-aleatorio/> )

<sup>51</sup>Wang, Y. and Wang, Z.-O., 2007. A Fast KNN Algorithm for Text Categorization. 2007 International Conference on Machine Learning and Cybernetics, IEEE, Vol. 6.

<sup>52</sup>Merkle, (2020). El algoritmo K-NN y su importancia en el modelado de datos, (disponible en: <https://www.merkleinc.com/es/es/blog/algoritmo-knn-modelado-datos> )

## Ilustración 2: Resultados de Orange



Fuente: elaboración propia a través de Orange

En la “Ilustración 2: Resultados de Orange” se han obtenido los resultados del *Machine Learning* realizado en nuestro modelo;

- **MSE:** mide el error cuadrático medio de nuestras predicciones, en un modelo perfecto el MSE sería cero. En nuestro caso, el MSE tiene un valor muy cercano a cero, resultando en un mismo valor en el *Random Forest* y en el *Knn*, de 0,182.
- **RMSE:** es la raíz cuadrada del MSE, por lo que hace que la escala de los errores sea igual a la escala de los objetivos.
- **MAE:** el error se calcula como un promedio de diferencias absolutas entre los valores objetivo y las predicciones, es una puntuación lineal, en la que todas las diferencias individuales se ponderan por igual en el promedio.
- **R<sup>2</sup>:** aquí la medida está libre de escala, y el valor siempre estará entre 0 y 1. En nuestro caso, todos los valores son positivos, lo que quiere decir que el modelo es mejor que predecir la media.

En este caso hasta caso en el RMSE, pues no se tienen valores atípicos en nuestro modelo, si no valores inesperados que se deben tener en cuenta. El RMSE “es la medida

de qué tan bien se ajusta una línea de regresión a los puntos de datos.”<sup>53</sup> Por ende, cuanto mayor sea el RMSE, mayor será la diferencia entre los valores predichos y observados, por lo que el ajuste del modelo a los datos será peor. El RMSE de nuestro Random Forest es de 0,427 por lo que es mejor que el de regresión.

## 7. CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

Las **startups** son un tipo de emprendimiento que ha generado una tendencia a nivel global influyendo en el funcionamiento de los distintos mercados. Su creación y funcionamiento aporta numerosos beneficios a la sociedad, entre los que destacan la creación de empleo y el fomento de la innovación.

Son 11 de cada 12 startups las que fracasan, y por ello es muy importante investigar cuales son los factores que provocan su éxito.<sup>54</sup> Tras una **revisión literaria** de estos factores que nos ha permitido comprender su importancia hemos descargado los datos de 152 startups de la plataforma *Crunchbase* para estudiar la relación entre los factores seleccionados y el éxito de las startups (que se ha medido según el número de rondas de financiación obtenidas por considerar que estas se reciben según los beneficios estimados de la startup).

Es imprescindible aclarar los resultados más importantes de nuestra investigación y recalcar las contribuciones más importantes aportadas a la literatura existente. En este sentido, nuestro estudio nos permite realizar las siguientes conclusiones:

En primer lugar, se ha elegido el **modelo de Poisson** por ser el más significativo en su conjunto, teniendo un contraste de significación global de  $1,40e^{-50}$  y ser este muy inferior a 0,01. Además, se trata de un modelo lineal con normalidad en los residuos y sin heterocedasticidad ni multicolinealidad. En relación con la predicción del modelo, sus proyecciones se ajustan muy bien al modelo excepto en los casos en los que las startups llegan a 12 o más rondas de financiación.

En segundo lugar, la variable dependiente “**número de rondas de financiación**”, que mide el éxito de las startups, está muy influida por el resto de las variables del modelo,

---

<sup>53</sup>AcervoLima, LM, Explicación matemática de RMSE y error R-cuadrado, (disponible en: <https://es.acervolima.com/ml-explicacion-matematica-de-rmse-y-error-r-cuadrado/>)

<sup>54</sup> Cerdeira, N., & Kotashev, K. (2021). Startup Failure Rate: Ultimate Report + Infographic. (Obtenido de Failory: <https://www.failory.com/blog/startupfailure-rate>)



pues su coeficiente de variación es muy alto, de 2,06. Y la media de rondas de financiación de las startups de las que hemos obtenido los datos es de 2,41.

En tercer lugar, las **variables especialmente significativas** del modelo son Sudamérica, CB Rank y Total Financiación, pues su  $\alpha = 0,01$ . Y las **variables no significativas** son Europa, Asia, África, N.º de empleados e industria, con un p.valor  $> 0,1$ .

En cuarto lugar, se ha realizado un pequeño modelo de *Machine Learning* en el que el resultado del RMSE del Random Forest nos resultó de 0,427, significando que este modelo es mejor que el de regresión de Poisson.

Se ha podido **responder a nuestra pregunta de investigación**: “¿*Tienen más éxito aquellas startups cuya actividad se desarrolla dentro de industrias consideradas modernas o aquellas enfocadas en sectores más tradicionales?*” Y la respuesta es que el hecho de que la industria en la que la startup desarrolle su actividad sea tecnológica o tradicional no es un factor determinante de su éxito.

En relación con el cumplimiento de **los objetivos** del trabajo podemos decir que los objetivos **primarios** (conocer cómo afecta cada factor a la probabilidad de éxito de una startup, y de estos, saber con certeza cuáles son los que influyen directamente en este éxito) se han conseguido, pues a partir de la literatura y del modelo de Poisson se ha podido conocer cuales son las variables significativas. Sin embargo, no se dispone de los datos de todas las startups de estas industrias, si no solo con aquellos de 257 startups, por lo que se podría continuar profundizando sobre el tema. Por ejemplo, gracias a este trabajo se puede decir que en Sudamérica las startups están teniendo un mayor éxito que en Europa, aunque para afirmarlo con total certeza se debería realizar un estudio contando con todas las startups creadas en ambos continentes.

En lo relativo a los **objetivos secundarios**, el primero era comprobar con exactitud la veracidad de nuestras hipótesis. Respecto a nuestras **hipótesis**:

- **No se cumplen ni la primera, ni la segunda, ni la cuarta**, pues con nuestro modelo hemos comprobado que las startups que dedican su actividad a la industria tecnológica, como el *blockchain* o las criptomonedas, no tienen por qué tener más éxito que aquellas que dedican su actividad a la industria tradicional como el alquiler de pisos. Además, en nuestra segunda hipótesis se establecía que aquellas startups fundadas por 3, 4 o 5 personas tenían más

éxito que el resto, y tampoco se ha podido validar. Sin embargo, si podemos confirmar la cita literaria de Siri Tejersen, un estudio de la economía que afirmó que “las empresas fundadas por **más de un individuo** suelen tener mejores perspectivas de crecimiento pues la existencia de un equipo emprendedor permite acceder a una mayor variedad de recursos, desarrollar más capacidades, y compartir riesgos y responsabilidades que llevan a fijarse objetivos más ambiciosos.”<sup>55</sup> En la cuarta hipótesis se estimaba que el orden del éxito según la localización de las startups era el siguiente: Norte América> Europa> Asia > América del Sur> Oceanía > África, pero el modelo ha confirmado que el orden es muy distinto, siendo este: Sudamérica> Oceanía> Asia> África> Europa. En el estudio de “Nuevas empresas en América latina: factores que favorecen su rápido crecimiento” concluyen que “existe una marcada necesidad de promover las actividades de los capitales de riesgo reduciendo la incertidumbre y el coste de inversión en las PYMES, especialmente en América Latina y Europa Mediterránea.”<sup>56</sup> Estableciendo que tanto en Sudamérica como en Europa es necesario invertir en el conocimiento humano respecto a las startups para que éstas puedan obtener financiación y proliferar, lo que por un lado coincide con nuestro estudio en el que Europa está situado último en el ranking de startups exitosas, pero difiere mucho en que América del Sur está situado el primero.

- **La única hipótesis que se ha podido validar es la tercera**, que afirmaba que las startups que han obtenido una cantidad total de financiación mayor han tenido más éxito.

El **segundo objetivo secundario** consistía en **aportar información relevante a la literatura existente** para poder ayudar a emprendedores, inversores y gobiernos en la toma de decisiones relacionadas con las startups. Podemos afirmar que si se ha cumplido, aunque esta información sería de mayor utilidad si la base de datos fuera mayor, si se tomaran más variables en consideración y si se recurriese a una mayor bibliografía, lo

---

<sup>55</sup> Terjesen, S. & Szerb, L. (2008). Dice thrown from the beginning? An empirical investigation of determinants of firm level growth expectations. *Estudios de Economía*, 35, 154-178.

<sup>56</sup> Federico, J., Kantis, H., & Rabetino, R. (2009). Factores determinantes del crecimiento en empresas jóvenes. Evidencias de una comparación internacional. *Nuevas empresas en América Latina: factores que favorecen su rápido crecimiento*, 21-52. (p.43).

cual no ha sido posible por limitaciones de espacio y tiempo por lo que este trabajo puede ser tomado como referencia para futuras investigaciones.

## 8. REFERENCIAS BIBLIOGRÁFICAS

- **1 Million bot, (2019).** 1MillionBot en Crunchbase la mayor base de datos del ecosistema startup, *Torre Juana*, (disponible en: <https://ost.torrejuana.es/1millionbot-ya-esta-en-crunchbase-la-mayor-base-de-datos-del-ecosistema-startup/#:~:text=El%20CB%20Rank%20esta%20basado,de%20noticias%20y%20las%20adquisiciones.> )
- **AcervoLima, LM,** Explicación matemática de RMSE y error R-cuadrado, (disponible en: <https://es.acervolima.com/ml-explicacion-matematica-de-rmse-y-error-r-cuadrado/> )
- **Acs, Z., P. Arenius, M. Hay, and M. Minniti. (2005).** 2004 Global Entrepreneurship Monitor. *London Business School and Babson College.*
- **Acs, Z., Morck, R., Shaver, J. & Yeung, B. (1997).** The internationalization of small and medium-sized enterprises: a policy perspective. *Small Business Economics*, 9, 7-20.
- **Alsos, G. A., & Kolvereid, L. (1998).** The business gestation process of novice, serial, and parallel business founders. *Entrepreneurship Theory and Practice*, 22, 101-114.
- **Arner, D. W., Barberis, J., & Buckley, R. P. (2015).** The evolution of Fintech: A new post-crisis paradigm. *Geo. J. Int'l L.*, 47.
- **Barringer, B., Foard, J., & Neubaum, D. (2005).** A Quantitative Content Analysis of the Characteristics of Rapid-Growth Firms and Their Founders. *Journal of Business Venturing*, 20, 663-687. (Obtenido de: [https://www.researchgate.net/publication/222426972\\_A\\_Quantitative\\_Content\\_Analysis\\_of\\_the\\_Characteristics\\_of\\_Rapid-Growth\\_Firms\\_and\\_Their\\_Founders](https://www.researchgate.net/publication/222426972_A_Quantitative_Content_Analysis_of_the_Characteristics_of_Rapid-Growth_Firms_and_Their_Founders))

- **Baliño, A. (2021).** *El origen de las Startups.* Hugo de la O. <https://hugodelao.com/que-es-startups/#:%7E:text=En%20lo%20que%20hoy%20se,junto%20con%20ocho%20j%C3%B3venes%20ingenieros.>
- **Bartesaghi, A., Lasio, V., Varela, R., Veiga, L., Kew, P. (2016).** GEM América latina y el Caribe 2015-2016, *Global Entrepreneurship Monitor*, (disponible en: [https://www.gemconsortium.org/file/open?fileId=49822&\\_ga=2.184450862.985493710.1647513366-1856045328.1647513366](https://www.gemconsortium.org/file/open?fileId=49822&_ga=2.184450862.985493710.1647513366-1856045328.1647513366) )
- **Bermejo, C., Megias, J., and Mitjavila M., (2019)** “Spain Startup Manifesto: El Manifiesto Del Ecosistema Emprendedor.”
- **Caballero, A. (2022, 24 mayo).** *¿Qué es el exit de una startup y qué opciones hay?* Keiretsu Forum Spain. <https://www.keiretsuforum.es/emprendedor/que-es-el-exit-de-una-startup-y-que-opciones-hay/>
- **Camarero García, Sebastián and Murmann, Martin (2020).** “Unemployment Benefit Duration and Startup Success.” *ZEW-Centre for European Economic Research Discussion Paper*, 20-33.
- **Capelleras, J. y Kantis, H. (2009).** Nuevas empresas en América Latina: factores que favorecen su rápido crecimiento. *Universidad Autónoma de Barcelona.* España.
- **Cerdeira, N., & Kotashev, K. (2021).** Startup Failure Rate: Ultimate Report + Infographic. (Obtenido de Failory: <https://www.failory.com/blog/startupfailure-rate> )
- **Chamizo, H., (2021).** 10 startups españolas del sector de las criptomonedas que los expertos tienen en su radar en 2021, *Business Insider*, (disponible en: <https://www.businessinsider.es/startups-espanolas-criptomonedas-fondos-tienen-radar-932773> )
- **Crunchbase: Discover innovative companies and the people behind them. (2022).** Crunchbase. <https://www.crunchbase.com/>
- **Dolfsma, W. and Seo, D. (2013).** Government policy and technological innovation—a suggested typology. *Technovation*, pp.173-179.

- **Eleconomista.Com.Mx Aenolastname. (2022).** *La experiencia laboral es fundamental para emprender.* AméricaEconomía | AméricaEconomía. <https://www.americaeconomia.com/articulos/notas/la-experiencia-laboral-es-fundamental-para-emprender>
- **Federico, J., Kantis, H., & Rabetino, R. (2009).** Factores determinantes del crecimiento en empresas jóvenes. Evidencias de una comparación internacional. *Nuevas empresas en América Latina: factores que favorecen su rápido crecimiento*, 21-52.
- **Fraser, H., (2012).** *Design Works: How to Tackle Your Toughest Innovation Challenges Through*, University Toronto Press.
- **Ghiro, L., Restuccia, F., D'Oro, S., Basagni, S., Melodia, T., Maccari, L., & Cigno, R. L. (2021).** What is a Blockchain? A Definition to Clarify the Role of the Blockchain in the Internet of Things. *arXiv preprint arXiv:2102.03750*.
- **Hackman, J., & Oldham, G. (1982).** Work Redesign. *Group & Organization Studies*, 7.
- **Horrell, M., Litan, R.E. & Marion, E. (2010).** After Inception: How Enduring is Job Creation by Startups?, *Kauffman Foundation Research Series: Firm Formation and Economic Growth*.
- **Iberdrola,** Qué es el machine learning, (disponible en: [https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatizado#:~:text=El%20Machine%20Learning%20es%20una,elaborar%20predicciones%20\(an%C3%A1lisis%20predictivo\)](https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatizado#:~:text=El%20Machine%20Learning%20es%20una,elaborar%20predicciones%20(an%C3%A1lisis%20predictivo)) ).
- **Kuckertz, A., Brändle, L., Gaudig, A., Hinderer, S., Reyes, C. A. M., Prochotta, A., ... & Berger, E. S. (2020).** Startups in times of crisis—A rapid response to the COVID-19 pandemic. *Journal of Business Venturing Insights*, 169.
- **Khan, Y. H. (2018).** The Effectiveness of Entrepreneurial Activities for Economic Development: A Route to Innovation and Job Generation. *SocioEconomic Challenges*, 32-40.

- **Kopera, S.; Wszendybył-Skulska, E.; Cebulak, J.; Grabowski, S. (2018)** Interdisciplinarity in Tech Startups Development—Case Study of ‘Unistartapp’ Project., 1–10.
- **Lucidchart**, ¿Qué es un diagrama de árboles de decisión? (disponible en: <https://www.lucidchart.com/pages/es/que-es-un-diagrama-de-arbol-de-decision> )
- **Lussier, R. N. (1995)**. Startup business advice from business owners to would-be entrepreneurs. *SAM Advanced Management Journal*, 60.
- **Martínez, C. R. (2022, 15 marzo)**. ¿Qué es una empresa unicornio? Las startups que más han triunfado. Thinking for Innovation. <https://www.iebschool.com/blog/companias-unicornio-lean-startup/>
- **Martínez, J., (2020)**. Random Forest (Bosque Aleatorio): combinando árboles, *IArtificial* (disponible en: <https://www.iartificial.net/random-forest-bosque-aleatorio/> )
- **Merkle, (2020)**. El algoritmo K-NN y su importancia en el modelado de datos, (disponible en: <https://www.merkleinc.com/es/es/blog/algoritmo-knn-modelado-datos> )
- **Modelos lineales generalizados. (2021)**. Modelos Lineales Generalizados. <https://www.ibm.com/docs/es/spss-statistics/SaaS?topic=statistics-generalized-linear-models>
- **Nutting, W., & Hubbard, D. (2009)**. Addresses by William Nutting and David Hubbard Nutting. *BiblioBazaar*, 53. (1-96).
- **One Hot Encoding | Interactive Chaos. (2022)**. One Hot Encoding. <https://interactivechaos.com/es/manual/tutorial-de-machine-learning/one-hot-encoding>
- **Otero, A. (2011)**. Factores claves en el proceso de acceder a recursos financieros en Colombia para nuevos empresarios. *Memorias XXI Congreso Latinoamericano sobre Espíritu Empresarial*. (Disponible en: [http://bibliotecadigital.icesi.edu.co/biblioteca\\_digital/bitstream/item/5387/1/7P8.pdf](http://bibliotecadigital.icesi.edu.co/biblioteca_digital/bitstream/item/5387/1/7P8.pdf) )
- **Rauch, A., & Frese, M. (2000)**. Psychological approaches to entrepreneurial success: A general model and an overview of findings. *International review of industrial and organizational psychology*, 15, 101-142.

- **Republic - Crunchbase Company Profile & Funding. (2022).** Crunchbase.  
<https://www.crunchbase.com/organization/republic-co>
- **Ries, E., & Salbut, B. (2012).** El método lean startup.
- **Rodó, P. (2021, 19 febrero).** *Multicolinealidad.* Economipedia.  
<https://economipedia.com/definiciones/multicolinealidad.html#:~:text=La%20multicolinealidad%20es%20la%20relaci%C3%B3n,m%C3%A1s%20de%20dos%20variables%20explicativas.>
- **Roure, J., & Keeley, R. (1990).** Predictors of Success in new technology based ventures. *Journal of Business Venturing*, 5, 4-15. (Obtenido de: [https://econpapers.repec.org/article/eeeejbvent/v\\_3a5\\_3ay\\_3a1990\\_3ai\\_3a4\\_3ap\\_3a2\\_01-220.htm](https://econpapers.repec.org/article/eeeejbvent/v_3a5_3ay_3a1990_3ai_3a4_3ap_3a2_01-220.htm) )
- **Salamzadeh, A., Kawamorita Kesim, H. (2015).** Startup Companies: Life Cycle and Challenges, *4th International Conference on Employment, Education and Entrepreneurship (EEE).*
- **Santisteban, J., & Mauricio, D. (2017).** Systematic Literature Review of Critical Success Factors of Information Technology Startups. *Academy of Entrepreneurship Journal*, 23.
- **Saura, J. R., Palos-Sanchez, P., & Grilo, A. (2019).** Detecting indicators for startup business success: Sentiment analysis using text data mining. *Sustainability*, 11.
- **Sepulveda, M. (2017).** (Obtenido de <https://pulsosocial.com/2017/06/12/mejora-la-productividad-startup/> )
- **Shane T, M. (2021, 24 febrero).** *Decision Trees, Random Forests, and Nearest-Neighbor classifiers.* Decision Trees, Random Forests, and Nearest-Neighbor classifiers.  
<https://pages.mtu.edu/~Eshanem/psy5220/daily/Day13/treesforestsKNN.html>
- **Szarek, J., & Piecuch, J. (2018).** The importance of startups for construction of innovative economies.

- **Terjesen, S. & Szerb, L. (2008).** Dice thrown from the beginning? An empirical investigation of determinants of firm level growth expectations. *Estudios de Economía*, 35.
- **The IT Factory. (2019, 29 diciembre).** *A importância da equipa de trabalho para o sucesso de uma startup.* Startup Knowledge Base. <https://www.the-itfactory.com/startup->
- **Vaillant, Y., Gómez, E., & Lafuente, E. (2011).** El impacto de factores socio-culturales sobre la actividad emprendedora de los jóvenes en España.
- **W. (2022, 24 febrero).** *Cómo funcionan las rondas de financiación.* Lean Finance. <https://leanfinance.es/rondas-de-financiacion/>
- **Wang, Y. and Wang, Z.-O., (2007).** A Fast KNN Algorithm for Text Categorization. 2007 International Conference on Machine Learning and Cybernetics, IEEE, Vol. 6.
- **Wątopek, M., Drożdż, S., Kwapien, J., Minati, L., Oświęcimka, P., & Stanuszek, M. (2021).** Multiscale characteristics of the emerging global cryptocurrency market. *Physics Reports*.