

# Grado de Administración y Dirección de Empresas

---

## Medición del impacto de siniestralidad multirriesgo industrial y climático:

Una propuesta para su gestión mediante una  
técnica de estadística y un método determinista

**Autoría:** Sonia Serra Grivina

**Tutoría:** Eva Boj del Val

**Departamento:** Departamento de  
Matemática Económica, Financiera  
y Actuarial

**Curso académico:** 2022-2023



UNIVERSITAT DE  
BARCELONA

Facultat d'Economia  
i Empresa

## Resumen

Este Trabajo Fin de Grado se centra en la medición del impacto de la siniestralidad multirriesgo industrial y climática en las provincias españolas, así como en la propuesta de una metodología para su evaluación cuantitativa. El objetivo principal es calcular las provisiones necesarias para hacer frente a estos eventos adversos, utilizando técnicas estadísticas.

En primer lugar, se analiza la siniestralidad multirriesgo en empresas industriales de las provincias españolas, identificando los factores industriales más frecuentes y propensos a su ocurrencia. Además, se realiza el cálculo de las provisiones necesarias para cuantificar económicamente el impacto de los fenómenos meteorológicos impredecibles en las provincias.

Para lograr estos objetivos, se emplea el software R para realizar los cálculos y se utiliza un enfoque basado en técnicas estadísticas, incluyendo el Análisis Factorial, para evaluar alternativas y tomar decisiones informadas. Se enfatiza la importancia de garantizar una gestión eficaz de la siniestralidad multirriesgo, especialmente en las provincias que presentan mayores costes medios por siniestro, para asegurar una cobertura preferente por parte de las entidades aseguradoras en España.

En conclusión, este trabajo propone una metodología integral que combina técnicas estadísticas y variables aleatorias para medir y gestionar el impacto económico de la siniestralidad multirriesgo en las provincias españolas. Los resultados obtenidos proporcionarán información valiosa para la toma de decisiones tanto en el sector asegurador como en el ámbito de la gestión de riesgos industriales y climáticos.

## Palabras clave

Siniestralidad multirriesgo, impacto económico, provincias españolas, medición, técnica estadística, variable aleatoria, provisiones, gestión eficaz, cobertura preferente, software R, Análisis Factorial, riesgos industriales, riesgos climáticos.

---

*“Estamos usando los resultados del año pasado como una heurística para predecir el valor de la firma en los próximos años. ¿Es esta heurística lo bastante buena? ¿Qué otra información necesitamos?”*

---

Premio Nobel de Economía Daniel Kahneman en “Pensar rápido, pensar despacio”

# ÍNDICE

<b>I. INTRODUCCIÓN</b> .....	<b>6</b>
1. MOTIVACIÓN EN LA ELECCIÓN DEL TEMA Y PROBLEMAS A LOS QUE ALUDE .....	6
2. OBJETIVOS DEL PROYECTO .....	6
<b>II. MARCO TEÓRICO DENTRO DEL CONTEXTO ASEGURADOR</b> .....	<b>7</b>
1. GESTIÓN DE LA SINIESTRALIDAD EN EL SECTOR ASEGURADOR ESPAÑOL .....	7
2. LA HUELLA DE LA DIGITALIZACIÓN QUE AFECTA AL SECTOR ASEGURADOR .....	8
3. SINIESTRALIDAD MULTIRRIESGO .....	9
3.1. <i>Siniestralidad industrial</i> .....	9
3.2. <i>Siniestros meteorológicos</i> .....	11
4. EL ANÁLISIS FACTORIAL APLICADO A LA GESTIÓN ASEGURADORA DE RIESGOS .....	14
5. CÁLCULO DE PROVISIONES TÉCNICAS ACTUARIALES .....	14
5.1. <i>Conceptos y definiciones clave</i> .....	15
5.2. <i>Herramientas y técnicas actuariales</i> .....	16
<b>III. BASES DE DATOS</b> .....	<b>16</b>
1. FUENTE DE INFORMACIÓN DE LAS BASES DE DATOS EXPORTADAS .....	16
<b>IV. APLICACIÓN PRÁCTICA</b> .....	<b>17</b>
<b>IV.I. CASO PRÁCTICO 1 (SINIESTRALIDAD INDUSTRIAL)</b> .....	<b>17</b>
1. PROCESO DE ANÁLISIS DE DATOS .....	17
2. ADECUACIÓN DE LOS DATOS PARA REALIZAR EL ANÁLISIS FACTORIAL .....	18
3. APLICACIÓN DEL ANÁLISIS FACTORIAL EN R .....	18
4. RESULTADOS Y CONCLUSIÓN .....	29
4.1. <i>Significación de los factores subyacentes</i> .....	29
4.2. <i>Afectaciones factoriales en las provincias españolas</i> .....	31
<b>IV.II. CASO PRÁCTICO 2 (SINIESTRALIDAD METEOROLÓGICA)</b> .....	<b>34</b>
1. DESCRIPCIÓN DE LA BASE DE DATOS TÉCNICA .....	34
1.1. <i>Obtención estimada del número de siniestros</i> .....	34
1.2. <i>Obtención del coste medio por siniestro</i> .....	37
2. HIPÓTESIS PLANTEADA .....	39
3. CÁLCULO DE PROVISIONES EN R .....	39
4. TRIÁNGULOS DE DESARROLLO .....	40
5. RESULTADOS Y CONCLUSIÓN .....	42
<b>V. CONCLUSIONES DESTACADAS</b> .....	<b>43</b>
1. SÍNTESIS DE LOS RESULTADOS .....	43
2. IMPLICACIONES EN LA GESTIÓN DE RIESGOS CONTEMPLADA EN SEGUROS MULTIRRIESGO .....	44
<b>VI. REFERENCIAS BIBLIOGRÁFICAS Y WEBGRAFIA</b> .....	<b>45</b>
<b>VII. ANEXOS</b> .....	<b>46</b>
1. HERRAMIENTA EN R: ELABORACIÓN DE MAPAS PARA EL ANÁLISIS FACTORIAL .....	46
2. HERRAMIENTA EN R: ESTIMACIÓN DE PROVISIONES MEDIANTE UN MENÚ DE SELECCIÓN PARA CUALQUIER TERRITORIO GEOGRÁFICO PROVINCIAL ESPAÑOL DE LOS SINIESTROS CLIMÁTICOS ENTRE LOS AÑOS 2017 Y 2021 .....	48
3. TABLA DE PROVISIONES PENDIENTES PARA LAS PROVINCIAS ESPAÑOLAS .....	49



# I. INTRODUCCIÓN

## 1. Motivación en la elección del tema y problemas a los que alude

En el último año de mi formación universitaria he tomado la conciencia de cómo asignaturas relacionadas con la Estadística y la Matemática aplicadas han moldeado mis intereses académicos. Es por ello por lo que este trabajo es fruto de una creciente inquietud en ambos campos.

Este Trabajo de Fin de Grado (TFG) aborda problemas en el campo estadístico-actuarial, donde se busca analizar variables de tipo aleatoria tales como la provisión matemática a calcular para cubrir los riesgos comprometidos y conseguir una gestión eficiente, o bien analizarlos factores de riesgos que inciden sobre la probabilidad de sufrir siniestros de una determinada variable y, de nuevo, prever el impacto en forma de eficiencia que pueda tener si formara parte de la contabilidad interna que lleva una entidad aseguradora o bancaria. El estudio de los cálculos de las provisiones resulta esencial para una toma de decisiones óptima por parte de los directivos en áreas financieras, actuariales y de gestión interna.

Esta problemática se relaciona y tiene implicaciones en aspectos como la creación de reservas matemáticas por parte de los aseguradores para mantener la solvencia futura y prevenir la quiebra empresarial, la generación de un fondo líquido suficiente para cumplir con las obligaciones pactadas, el cumplimiento de la legislación vigente para una adecuada gestión de los posibles siniestros y la estimación precisa de las provisiones, teniendo en cuenta la inflación y otros factores que pueden afectar a su capitalización.

## 2. Objetivos del proyecto

El proyecto busca medir el impacto de los factores de riesgo en una cartera específica de seguros de tipo multirriesgo (industrial) y el cálculo de la provisión matemática en otra cartera específica del propio ramo (climática), utilizando una base de datos técnica y las metodologías proporcionadas por el software R. A fin de gestionar de la mejor manera los riesgos en forma de siniestros que sufren los asegurados en una empresa real, el estudio exporta unos datos que realmente han tenido lugar.

En este TFG también se pretende introducir una nueva metodología de gestión por las empresas aseguradoras españolas. La metodología pretende posicionar a las empresas de puestos geográficamente para considerar una tipología de siniestralidad más relevante y actuar en consonancia y coherencia a la hora de hacer frente a los pagos, en función de las conclusiones derivadas de un análisis multivariante.

## II. MARCO TEÓRICO DENTRO DEL CONTEXTO ASEGURADOR

### 1. Gestión de la siniestralidad en el sector asegurador español

Las compañías de seguros en España deben implementar estrategias de gestión de riesgos y prevención de siniestros para hacer frente a sus desafíos en un entorno donde se generan situaciones de difícil predictibilidad, como el análisis de los factores que inciden en el riesgo de una determinada variable, el uso de tecnologías de la información y velar por la seguridad de los asegurados con éxito. Para lograrlo con garantías, los aseguradores cuentan con herramientas como el análisis de datos y el uso de modelos predictivos para ayudarles a anticipar tendencias y adaptarse a las nuevas condiciones del mercado.

Los aseguradores deben protegerse o remediar todo aquello que no pueden controlar bajo un plan estratégico estrictamente regulado por la DGSFP. Por esta razón, además de las provisiones que capitalizan para establecer una reserva futura, una parte de su capital remanente se guarda para ser reinvertida en la compra o venta de una gran variedad de instrumentos financieros. En el sector asegurador, la siniestralidad se mide generalmente a través de dos indicadores: la frecuencia y el coste de los siniestros ocurridos. La frecuencia se refiere al número de siniestros ocurridos en un período de tiempo, mientras que el coste alude al coste promedio de los siniestros mencionados y cubrir el riesgo estipulado en la póliza de seguro del cliente. Sin embargo, hay veces que este riesgo es tan grande que supera la cantidad a la que puede hacer frente la misma aseguradora. En estos casos, de acuerdo con la normativa dictaminada por la Dirección General de Seguros y Fondos de Pensiones, la misma aseguradora puede traspasar la obligación de cobertura a un organismo llamado Consorcio de Compensación de Seguros.

Por otro lado, el índice de siniestralidad en el mundo asegurador es un indicador clave para evaluar la siniestralidad en el sector asegurador. Este índice se calcula como el cociente entre las indemnizaciones pagadas por la aseguradora y las primas devengadas. Un índice de siniestralidad elevado puede indicar que una aseguradora está cubriendo un número alto de siniestros o que estos son de gran magnitud, lo que afecta su rentabilidad y solidez financiera.

Cabe destacar que el concepto de siniestralidad es imprescindible para las compañías aseguradoras dado que permite evaluar su cumplimiento en los pagos a realizar y gestionar sus riesgos de forma efectiva.

Desde una perspectiva actuarial, un índice de siniestralidad elevado puede ser motivo de preocupación para las aseguradoras, ya que puede indicar una exposición mayor al riesgo, una gestión de riesgos inadecuada o una política de suscripción insostenible. En este sentido, las aseguradoras deben analizar con cuidado las causas subyacentes del aumento de la siniestralidad y tomar medidas

para mejorar su gestión de riesgos, revisar sus políticas de suscripción y asegurar una adecuada tarificación de las primas.

Por otro lado, una siniestralidad más baja puede indicar una gestión eficiente de riesgos y una política de suscripción prudente. Sin embargo, es importante tener en cuenta que una siniestralidad muy baja también puede ser el resultado de una política de suscripción excesivamente conservadora, lo que podría limitar la capacidad de la aseguradora para crecer y competir en el mercado. La materialización de los riesgos puede verse afectada por diversos factores, como el contexto económico, las condiciones climáticas, los cambios demográficos y las tendencias en el comportamiento de los asegurados, entre otros.

Por ejemplo, las crisis de la burbuja inmobiliaria del año 2008 y la sanitaria del 2020 tuvieron un impacto negativo en la siniestralidad de los seguros de automóviles y del hogar, debido a la reducción de la actividad económica y la menor inversión en bienes asegurados. Las empresas tuvieron que disminuir las primas y, por lo tanto, reducir la cobertura de los seguros contratados. La mayor incidencia de siniestros acabó afectando a las entidades que proporcionaban cobertura, las cuales no podían cubrir todo el costo de los siniestros reales. En otras palabras, lo que reclamaban los asegurados superaba los ingresos por primas que cobraron en su día las aseguradoras.

En los últimos años, el sector asegurador español ha experimentado una tendencia a la baja en la siniestralidad, gracias a una recuperación económica en tiempo récord después de la pandemia del Covid-19 y la implementación de medidas para mejorar la gestión de riesgos. Sin embargo, continúan existiendo desafíos importantes, como el envejecimiento de la población y los efectos del cambio climático, que pueden incidir en la siniestralidad futura.

## **2. La huella de la digitalización que afecta al sector asegurador**

La presencia de la revolucionaria industria tecnológica 4.0 viene acompañada de nuevos descubrimientos que pretenden dar solución en su línea de actuación a los nuevos interrogantes actuales y potenciales necesidades que atraviesa la sociedad actual. El avance digital es una realidad cada vez más tangible y, en consecuencia, imparable en cuanto a la búsqueda de nuevas formas más productivas de llevar la gestión de cualquier empresa y el sector asegurador no es la excepción. El uso del software R en el ámbito asegurador ha sido un proceso evolutivo que ha tenido lugar en las últimas dos décadas aproximadamente. Esta plataforma libre y gratuita ha sido impulsada por factores como el crecimiento exponencial de los datos disponibles y la necesidad de analizar y procesar grandes volúmenes de información para la evaluación de riesgos y la toma de decisiones. También ha influido su uso por un auge de demanda relativa a métodos de modelización actuarial para analizar la siniestralidad. De todos aquellos sucesos que pueden causar siniestros, se comentarán los relacionados con la actividad industrial o laboral y la provocada por fenómenos meteorológicos o catastróficos.



### 3. Siniestralidad multirriesgo

#### 3.1. Siniestralidad industrial


La siniestralidad industrial, como se ha mencionado previamente, incluye todos los accidentes, incidentes y contratiempos que pueden ocurrir en el entorno laboral dentro del sector industrial. Estos eventos pueden variar en magnitud y gravedad, sumando las situaciones como averías de maquinaria, incendios industriales, explosiones, derrames de sustancias químicas, robos, accidentes laborales, entre otros que se comentarán posteriormente (Caso Práctico 1). La siniestralidad industrial es un subconjunto de la siniestralidad laboral, específicamente enfocado en el sector industrial. Los accidentes y bajas que ocurren en entornos industriales, como fábricas, plantas de producción y almacenes, se consideran tanto parte de la siniestralidad laboral como de la siniestralidad industrial. Cabe decir que cada sector laboral puede tener riesgos específicos, dependiendo si hay cierta relación con la actividad industrial.

##### 3.1.1. El índice de incidencia

La siniestralidad laboral es un tema de gran relevancia, particularmente en la industria de la construcción, donde los índices de accidentes son significativamente altos. El índice de incidencia es la medida estadística que más se utiliza en las distintas publicaciones en este ámbito. Se construye tomando la relación del número de accidentes de un grupo concreto de trabajadores en riesgo durante un determinado horizonte temporal. De forma generalizada y para una comprensible interpretación se suele multiplicar por 100.000 empleados. No se incluyen los accidentes que el empleado tuviese fuera de su horario laboral o durante el trayecto. El indicador sirve para evaluar la seguridad en el sector industrial, dado que permite identificar áreas de riesgo y analizar el rendimiento en materia de seguridad en las diversas empresas y de su sector en conjunto. Un valor alto del índice de incidencia indica la presencia de deficiencias en la gestión de riesgos, en la formación de los trabajadores, en la implementación de medidas preventivas, mantenimiento de las instalaciones y equipos.

Según los datos que proporcionan el *Ministerio de Trabajo y el Instituto Nacional de Seguridad y Salud en el Trabajo* el índice de incidencia en 2020 fue de 5.804,1 accidentes de trabajo en jornada de trabajo por cada 100.000 trabajadores, siendo la construcción el sector con mayor índice.

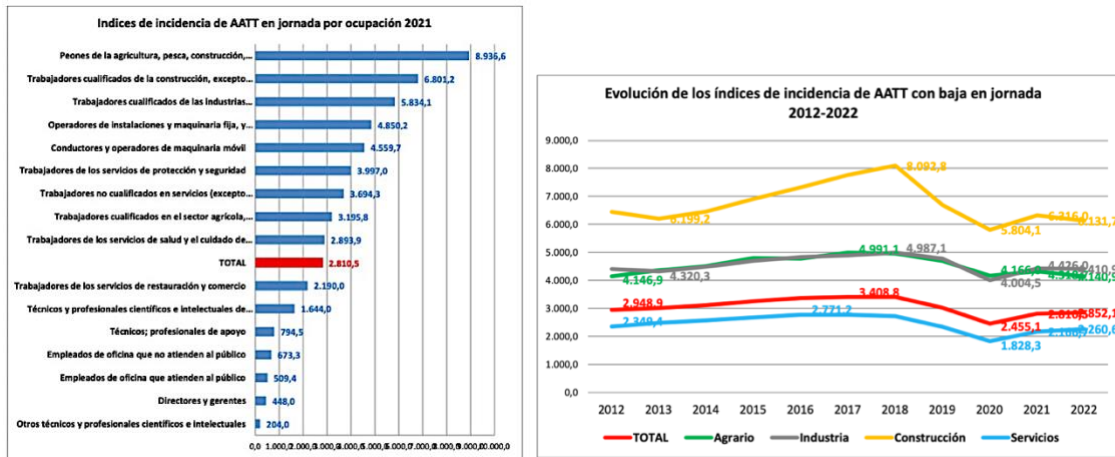
Gráfico 5. Índices de incidencia sectoriales de accidentes de trabajo en jornada de trabajo.



Fuente: Elaboración del INSST a partir del Fichero de microdatos de accidentes de trabajo 2020. MITES.

Fuente: Ministerio de Trabajo y Economía social (MTYES) y Dirección General de Política Energética y Minas (MITECO)

### 3.1.2. Accidentabilidad y preocupante mortalidad laboral en el sector industrial



Fuente de ambas ilustraciones: "Análisis de las estadísticas de accidentes de Trabajo y enfermedades profesionales en España en 2022" publicado por la Confederación Sindical de CCOO el recinto 14/02/2023.

Una vez más, se visualiza el elevado índice de accidentabilidad laboral en empresas de tipo industrial. La agricultura, la industria y la construcción son los sectores más afectados por accidentes laborales. La preocupación por la siniestralidad laboral sigue siendo alta y se agrava ante una perspectiva de mayor crecimiento futuro del sector constructor, aunque los últimos años se haya reducido y mantenido debido a Covid-19.

### 3.1.3. Factores de riesgos laborales en el sector industrial

Resulta imprescindible identificar, evaluar y controlar los riesgos laborales promoviendo una cultura de prevención y seguridad en el trabajo para incidir sobre la accidentabilidad. Los factores de riesgo del aumento de la siniestralidad se explican por una precariedad laboral explicada por la falta de formación y la insuficiencia en la inspección y control de las obras. Esta situación la causa una falta de medidas y control por parte de la administración para garantizar el cumplimiento de las leyes de subcontratación y prevención de riesgos laborales. La seguridad y salud laboral son claves para reducir la siniestralidad en el sector.

El fenómeno económico inflacionario que ha venido experimentando un crecimiento notable en los últimos meses a nivel global tiene repercusiones directas en el sector de servicios, especialmente en el ámbito de los seguros laborales por parte de las entidades aseguradoras. La ley establece que las primas de los seguros deben ser suficientes para cubrir las obligaciones derivadas de los contratos, lo cual implica que deben tener en cuenta el riesgo de siniestro. Ante la previsión de que la inflación continúe en ascenso en los próximos meses, es posible que las tasas de siniestralidad laboral aumenten debido a insuficiencias en las reservas del mercado reasegurador. Esto llevaría a las reaseguradoras a ajustar precios y tener que adoptar una suscripción más disciplinada y exigente, lo que tendría un impacto directo en el mercado asegurador local y tradicional.

### 3.1.4. Medidas preventivas para reducir los siniestros en empresas industriales

El paquete de medidas "anti siniestros" son soluciones preventivas u otros instrumentos que se ponen en marcha para tratar de disminuir el índice de incidencia de los accidentes en el sector de la industria con una organizada y correcto funcionamiento de los sistemas gestión y prevención de riesgos para velar por la salud y seguridad de los empleades. Las medidas preventivas de la accidentabilidad no solo pretenden reducir la siniestralidad industrial (e.g. reducir la probabilidad de averías), también mejorar las condiciones laborales.

- Capacitar y formar a los trabajadores en seguridad laboral y manejo de maquinaria y equipos para garantizar un entorno laboral seguro.
- Mantener y actualizar adecuadamente la maquinaria y equipos necesarios.
- Adoptar medidas de protección colectiva, siendo sistemas de ventilación y señalización, e individual, siendo equipos de protección individual para el desempeño adecuado de sus tareas.

Dado que el tejido empresarial español ésta compuesto mayoritariamente por pequeñas y medianas empresas (Pymes), no es de extrañar que el mayor porcentaje de siniestros ocurre en una empresa de entre 1 y 50 trabajadores, como son estas. En concreto, un 85% de los percances laborales en 2018 tuvieron lugar en una empresa del tipo más numeroso en España. Las empresas de tamaño más grande suelen subcontratar los autónomos propietarios de estas Pymes, dada su elevada vulnerabilidad a padecer siniestros. Comisiones Obreras (CCOO) insiste en adaptar la normativa de la Ley de Prevención de Riesgos actual a los autónomos.

### 3.2. Siniestros meteorológicos

La siniestralidad meteorológica es un término que engloba el impacto económico y material de eventos climáticos extremos, como tormentas, inundaciones, sequías, huracanes, oleadas de calor, entre otros. Estos acontecimientos pueden causar daños significativos a infraestructuras, propiedades, bienes y vida humana, y en consecuencia generan pérdidas económicas considerables a nivel local, regional y global. También afecta a las cosechas agrarias y ganaderas, en el campo, accidentes en las casas, accidentes de tráfico de los conductores (DGT), siniestralidad vial, multas por exceso de velocidad, incendios forestales, transporte aéreo y marítimo de mercancías, explosiones y la siniestralidad laboral e industrial. Los daños meteorológicos se materializan por sucesos de temporal como el granizo, lluvia, nieve, tormenta, precipitaciones, huracanes, catástrofes naturales o inundaciones.

El sector asegurador desempeña un papel fundamental en la gestión de riesgos asociados a la siniestralidad meteorológica, fenómeno de creciente importancia que afecta también cada vez más a la sociedad en general. Las compañías de seguros ofrecen coberturas para proteger a particulares, empresas y gobiernos de las pérdidas financieras ocasionadas por estos eventos extremos. Sin embargo, en los

últimos años, el aumento en la frecuencia y la intensidad de estos fenómenos ha generado una mayor presión sobre el sector, llevándolo a replantear sus estrategias de evaluación de riesgos ya adaptar sus productos y servicios. El cambio climático, resultado de la acumulación de gases de efecto invernadero en la atmósfera, ha sido identificado como un factor clave en la intensificación y el aumento de la frecuencia de eventos climáticos extremos. El fomento políticas de prácticas sostenibles y desarrollo de estrategias de mitigación para contribuir a concienciar a la sociedad sobre los riesgos asociados al cambio climático. Por su parte, las aseguradoras pueden incorporar criterios ambientales o sociales a sus inversiones para fomentar medidas de prevención y adaptación efectivas, como seleccionar proyectos para financiarlos.

### 3.2.1. Histórico climático de los recientes años

Entre 2017 y 2021, las aseguradoras en España desembolsaron casi 3.8 mil millones de euros en respuesta a 3.9 millones de reclamaciones de siniestros climáticos. En 2022 se produjo una disminución del 30% en las reclamaciones de siniestros climáticos por ausencia de eventos tan extremos como la tormenta Filomena en 2021. A pesar de la disminución en 2022, distintas aseguradoras enfatizan la importancia de estar preparados para eventos climáticos extremos.

### 3.2.2. Zonas más vulnerables a los incidentes climáticos

Durante 2022, Canarias, Levante (Valencia, Alicante, Murcia) e Islas Baleares fueron las zonas más impactadas por fenómenos meteorológicos como tormentas subtropicales, DANA (Depresión Aislada a Niveles Altos, también llama “gota fría”). Varias regiones de España también se vieron afectadas en gran medida por lluvias abundantes y borrascas en el noroeste peninsular, centro, sur y oeste.

### 3.2.3. Distribución de los costes y los siniestros

Tabla 1: Panorama de los siniestros meteorológicos en el seguro multirriesgo español

AÑO	HOGARES Y COM. DE PROP.	COMERCIO	INDUSTRIAS	OTROS	TOTAL
2017	590.686	31.075	30.037	2.106	<b>653.905</b>
2018	747.646	39.221	37.967	2.831	<b>827.667</b>
2019	696.364	34.902	35.772	2.087	<b>769.127</b>
2020	783.027	35.327	40.687	2.181	<b>861.223</b>
2021	698.645	30.156	38.756	1.643	<b>769.202</b>
<b>Total</b>	<b>3.516.368</b>	<b>170.681</b>	<b>183.219</b>	<b>10.848</b>	<b>3.881.124</b>

Informe de UNESPA. El Seguro y la Sostenibilidad Climática. Siniestralidad meteorológica pagada por las aseguradoras 2017-2021

Los siniestros meteorológicos generan un pago significativo para las aseguradoras, oscilando entre 650 y 1.000 millones de euros anuales, con un número total de siniestros entre 650.000 y 850.000 en todo el país. Estos incidentes representaron el 16.8% de todos los siniestros en seguros Multirriesgo, con la mayoría de los pagos dirigidos a viviendas y comunidades de propietarios. En cuanto a la distribución de los siniestros, la mayoría (entre el 65% y el 70%) están relacionados con seguros de hogar y edificios, seguidos por siniestros en empresas (22%) y automóviles (8%).


Tabla 3: Panorama de los costes medios meteorológicos en el seguro multirriesgo español

AÑO	HOGARES Y COM. DE PROP.	COMERCIO	INDUSTRIAS	OTROS	TOTAL
2017	678,33 €	1.549,09 €	6.107,81 €	14.058,48 €	<b>1.012,20 €</b>
2018	565,16 €	1.475,98 €	4.904,56 €	6.563,35 €	<b>827,90 €</b>
2019	686,31 €	1.535,28 €	5.643,49 €	15.539,10 €	<b>995,69 €</b>
2020	728,85 €	1.785,51 €	7.732,67 €	10.080,87 €	<b>1.126,76 €</b>
2021	629,95 €	1.687,75 €	5.489,02 €	5.219,37 €	<b>926,05 €</b>
<b>Total</b>	<b>657,49 €</b>	<b>1.602,89 €</b>	<b>5.997,75 €</b>	<b>10.248,89 €</b>	<b>977,97 €</b>

Fuente: Informe “El seguro y la sostenibilidad climática. Siniestralidad meteorológica pagada por las aseguradoras 2017-2021

Los siniestros más costosos ocurrieron en industrias, con un coste medio de alrededor de 6.000 euros por siniestro, en comparación con los 657 euros de los siniestros en viviendas. Las provincias más pobladas, como Madrid, Barcelona, Valencia y Alicante, tienen una mayor siniestralidad atmosférica. Barcelona (15%) lidera el ranking en términos de costes, seguida de Madrid (10%) y Alicante. Las provincias menos pobladas, como Soria, Palencia y Zamora, presentan una concentración menor de siniestros.

Ilustración 1: Composición de siniestros y los costes meteorológicos del multirriesgo, por tipologías



Fuente: Informe “El seguro y la sostenibilidad climática. Siniestralidad meteorológica pagada por las aseguradoras 2017-2021

Las ilustraciones destacan el gran peso que tienen los hogares y las comunidades de propietarios, tanto en lo que se refiere a los siniestros como al coste que les

supone cubrirlos. Así, los hogares y comunidades representan un 90% de los siniestros totales en comparación con el poco significativo 5% que sufren las industrias. En contrapartida, supone un coste del 60% y 30% respectivamente sobre el total. El coste medio por siniestro ocurrido en las empresas industriales es nueve veces más que el de los hogares, a pesar de suponer pocos siniestros respecto al total. En la muestra aparecen las cuantías que las aseguradoras cubren sólo por las empresas industriales, que presentan pocos siniestros, pero resultan más caros que el resto.

#### *3.2.4. Pronósticos de incidencia de fenómenos catastróficos*

En relación con la siniestralidad climática, un informe de la patronal revela que las provincias más pobladas de España presentan una mayor incidencia. Madrid lidera en densidad de siniestros climáticos, seguida de Barcelona, Valencia, Alicante y Murcia. Sin embargo, al analizar la probabilidad de siniestro meteorológico, se observa que el centro de la península y la costa mediterránea, incluyendo las Islas Baleares, tienen una mayor probabilidad. Por el contrario, Andalucía occidental, el País Vasco y Navarra presentan una probabilidad baja. Los costes medios de los siniestros varían entre provincias, siendo Almería la más elevada, mientras que Las Palmas registra el promedio más bajo. Los eventos climáticos como las tormentas Gloria y Filomena han supuesto desembolsos significativos para las aseguradoras. La inflación incide en el aumento del precio de las primas de seguros, por ello, el valor de la prima puede incrementarse debido a cambios en el riesgo o aparición de nuevos riesgos, como es el caso del cambio climático que genera nuevas condiciones meteorológicas adversas en lugares donde anteriormente no existían. La rentabilidad del mercado reasegurador en este escenario de inflación persistente podría verse afectada, especialmente en un contexto donde los siniestros por catástrofes meteorológicas están en aumento.

### **4. El Análisis Factorial aplicado a la gestión aseguradora de riesgos**

El Análisis Factorial es una técnica estadística multivariante que identifica los factores subyacentes que contribuyen a la variabilidad en la exposición al riesgo de diferentes pólizas de seguro, reduciendo la dimensionalidad de un conjunto de variables observadas a un número más pequeño de factores. Esta técnica se aplica en la evaluación de alternativas en el sector asegurador mediante el diseño de estrategias de prevención y mitigación de riesgos efectivas con el objetivo de una mejor y mayor comprensión de las causas de los siniestros. Al comprender qué factores contribuyen en el riesgo de siniestralidad desde un contexto de evaluación de riesgos, las aseguradoras toman decisiones más informadas sobre la suscripción de pólizas y la fijación de primas.

### **5. Cálculo de provisiones técnicas actuariales**

El cálculo de las provisiones técnicas constituye una parte fundamental de la gestión del riesgo en una compañía de seguros. En primer lugar, para garantizar recursos

suficientes que puedan cubrir obligaciones futuras de las compañías de seguro. El cálculo de reservas ayuda al mantenimiento de una posición financiera sólida incidiendo sobre la viabilidad y sostenibilidad de la entidad a largo plazo.

La obligatoriedad de protección y seguridad transferida que la entidad afronta sobre el riesgo contraído del asegurado expreso en la póliza supone el principal elemento para la confección de cualquier contrato de seguro. En este contrato se fijan cuestiones relativas al reembolso de beneficios prometidos como las cantidades soportadas por el asegurado franquiciado, entre otros. El cumplimiento de estos requisitos regulatorios es crucial para la operación continua de la entidad en el mercado asegurador y mantener la confianza de clientes y reguladores, pues las autoridades supervisoras velan por intereses de los afiliados.

La provisión adecuada se calcula en base a los riesgos asociados que las entidades identifican y pronostican para lidiar con situaciones de carácter exógeno o macroeconómico como la volatilidad de las tasas de interés y la inflación. Una vez la entidad asume los riesgos, buscará la rentabilidad y sostenibilidad de la compañía estableciendo primas y contribuciones adicionales para cubrir (inversiones) mediante un proceso de valoración y tarificación óptima de sus productos. Este proceso condicionará, sin lugar a duda, las provisiones técnicas futuras.

## 5.1. Conceptos y definiciones clave

### 5.1.1. *Provisión matemática*

La provisión matemática, en el ámbito puramente matemático-actuarial, se refiere a la cantidad de dinero que una compañía de seguros o un fondo de pensiones debe reservar para cumplir con las futuras obligaciones derivadas de los contratos de seguros y pensiones vigentes. Estas deben garantizar que la compañía tenga suficientes fondos disponibles para pagar indemnizaciones a sus asegurados en caso de siniestros, tal y como se apuntaba en el anterior subepígrafe. El cálculo de la provisión matemática se basa en métodos y modelos matemático-actuariales que consideran la experiencia pasada de la compañía en términos de siniestros y pagos, así como las tendencias y patrones observados en la industria.

### 5.1.2. *Triángulo de desarrollo*

El triángulo de desarrollo, también conocido como triángulo de cuantías o de run-off, es una herramienta comúnmente utilizada en la industria del seguro para analizar lo que las entidades deberían desembolsar líquidamente en forma de pagos a lo largo de un tiempo (años de desarrollo) en función del coste que los siniestros de una determinada categoría supusieron en un año de origen concreto. El primer número en cada fila es el importe inicial de los siniestros reportados en un año específico y las cifras siguientes representan cantidades a pagar de, que de manera acumulada, conforman el importe inicial a lo largo de los siguientes años.

## 5.2. Herramientas y técnicas actuariales

### 5.2.1. Selección del método actuarial

El método determinista de desarrollo de triángulos Chain Ladder es una técnica actuarial que estima las provisiones técnicas de una entidad aseguradora. Por ello, se hace una serie de proyecciones para identificar la cuantía de las liquidaciones a hacer frente en base al coste inicial o pago acumulado anterior de los siniestros ocurridos en determinados años de origen. Estas reservas futuras necesarias se calcularán una vez estén estimados los siniestros acumulados pendientes de pago, procediendo para su correspondiente cobertura bajo la presunción de unos patrones históricos de desarrollo de siniestros lineales.

La presente estimación de la provisión técnica o reserva estimada para cada período de suscripción es la diferencia entre el coste de los siniestros acumulados proyectados y el coste de los siniestros acumulados conocidos, es decir, la reserva como cantidad por pagar en un futuro deduciendo la cantidad pagada por siniestros que ya han tenido lugar. La reserva total es la suma de las reservas estimadas para todos los períodos de suscripción. En este caso, se considera que el período de suscripción coincide con el período de origen, siendo este último el período de ocurrencia de los siniestros y la posibilidad de poder reclamar los siniestros para cubrir durante períodos anuales. Más adelante, en el CASO PRÁCTICO 2, se mostrará un análisis comparativo entre los distintos territorios provinciales españoles con relación a este monto de desembolso futuro. Sin embargo, el método cuenta con algunas limitaciones. Y es que asume un desarrollo lineal de reclamaciones basado en patrones históricos, por lo que no suele ser preciso. Adicionalmente, su eficacia se ve limitada cuando los datos inestables llevan a estimaciones no muy precisas. Este método tampoco puede detectar o estimar tendencias a largo plazo en los datos de siniestros ni considerar cambios en la exposición al riesgo a lo largo del tiempo, como podría ser la inflación subyacente.

## III. BASES DE DATOS

### 1. Fuente de información de las bases de datos exportadas

Las bases de datos de estudio se exportan de UNESPA, una Asociación Empresarial del Seguro en España que representa a la mayoría de las empresas aseguradoras que operan en el país. Destaca por proporcionar información y formación sobre seguros a los consumidores, así como fomentar la I+D en el sector (Investigación y Desarrollo).



*16 entidades representativas en España colaboran en la cesión de información de interés siniestral a la asociación UNESPA*



- La tabla "Tabla 6: Distribución vertical de los contratiempos industriales, por provincias" en el informe de UNESPA "Siniestros Industriales. DATOS 2021-2022" y es la Base de Datos utilizada en el **CASO PRÁCTICO 1**.
- Las tablas "Tabla 6: Distribución de los siniestros meteorológicos del seguro multirriesgo, por provincias" y "Tabla 9: Costos medios de los siniestros meteorológicos del multirriesgo, por provincias", elaborada por UNESPA en "El seguro y la sostenibilidad climática. Siniestralidad meteorológica pagada por las aseguradoras 2017-2021" y es la Base de Datos utilizada en el **CASO PRÁCTICO 2**.

## IV. APLICACIÓN PRÁCTICA

### IV.I. CASO PRÁCTICO 1 (SINIESTRALIDAD INDUSTRIAL)

#### 1. Proceso de análisis de datos

La base de datos comprende 8 tipologías de siniestros (columnas para el análisis) para cada una de las 50 provincias españolas (filas para el análisis).

1) Avería de maquinaria	5) Multirriesgo industrial
2) Equipos electrónicos	6) Índice de Robos
3) Incendios industriales	7) Transportes cascos
4) Montaje	8) Transportes mercaderías

Por lo tanto, se trabajará con 50 casos (provincias españolas) frente a 8 variables determinantes o elementos analizados. Los factores obtenidos en el Análisis Factorial representan áreas de riesgo, es decir, agrupaciones de variables latentes que tienen altas correlaciones entre sí. La información proporcionada por la matriz de correlaciones se traduce en una mejor comprensión de cómo se relacionan los tipos de siniestros entre sí. La agrupación resultante (o combinación de los factores de las variables más correlacionadas) permite que la empresa de seguros administre los recursos en estas áreas de manera conjunta.

El hecho de que la unidad de trabajo sea el porcentaje conduce a la idea de que cuanto mayor sea la contribución del factor expuesto, mayor atención y preocupación por parte de la aseguradora para llevar a cabo el desembolso más grande que debe afrontar, lo cual probablemente ocurra a largo plazo.

Una vez analizado, se identifican cuáles han sido las áreas de riesgo de las provincias españolas que han necesitado más financiamiento para pagar sus siniestros en empresas industriales por parte de las compañías aseguradoras. El contenido de la tabla presenta información sobre incidentes o accidentes a nivel industrial, organizados verticalmente y desglosados por provincias. De esta manera, se pretende comparar los contratiempos industriales entre las diferentes provincias,

como analizar la frecuencia o gravedad de los incidentes ocurridos en el sector industrial entre ellas. Cada celda numérica en la base de datos tiene como valor la contribución en términos porcentuales de un solo tipo de contratiempo (previamente desglosados, del 1 al 8) a las empresas industriales de una determinada provincia española con respecto al total de este tipo de siniestros en todas las empresas industriales españolas.

## 2. Adecuación de los datos para realizar el Análisis Factorial

Existen numerosos estudios estadísticos que sostienen que debe haber al menos 5 casos por variable, es decir, 5 provincias por cada tipo de siniestro analizado. Dado que hay 8 tipos, se necesitarían al menos 40 provincias para realizar el respectivo análisis. Es importante mencionar que este criterio es muy variable y hay mucha discrepancia al respecto. Sin embargo, de acuerdo con los estudios mencionados y su amplia confiabilidad, consideraremos válida la matriz de datos para ser analizada mediante Análisis Factorial Exploratorio.

## 3. Aplicación del Análisis Factorial en R

El primer paso es cargar hoja o fichero de Excel.xlsx donde se almacena la información para el estudio, en este caso, la base de datos con los porcentajes sin dividir entre 100 de siniestros ocurridos por distintas razones guardadas en las variables relativas a la siniestralidad industrial previamente mencionadas.

```
library(readxl)
data <- read_excel("~/Desktop/tfg/data.xlsx", sheet = "Dades")
View(data)
summary(data)
print(data)

# A tibble: 50 × 9
  Provincia `AV. MAQ CONSTR` `EQ. ELEC.` INCEND. MONT. MULT.
  <chr>          <dbl>          <dbl> <dbl> <dbl> <dbl>
1 Álava          0.59            0.45    2.13  0.87  0.44
2 Albacete       0.88            0.4     0     0.48  0.22
3 Alicante       2.24            4.12    1.7   3.44  1.11
4 Almería        0.58            0.99    1.28  0.53  3.1
5 Asturias       2.41            1.86    1.49  0.59  0
6 Ávila          0.23            0.06    0.32  0.02  0.22
7 Badajoz        1.6             0.51    1.17  1.07  6.64
8 Barcelona      7.68            20.3    28.2  5.29  18.1
9 Burgos         1.25            0.34    0.43  0.28  0.88
10 Cáceres       0.35            0.48    0.11  0.3   0.22
# 40 more rows
# 3 more variables: `IND. ROBO` <dbl>, `TR. CASCOS` <dbl>,
# `TR. MERC.` <dbl>
```

```
# Use `print(n = ...)` to see more rows
```

Una vez cargada la base de datos y guardada como el objeto “data”, se procede a seleccionar las columnas o filas de interés para el análisis. En R se puede abstraer cualquier objeto mediante [i,j], donde la letra “i” simboliza el número de filas que posee la base de datos original y “j” el número de columnas de la misma. Se crea una matriz cuantitativa o numérica “x” de datos a partir del primer objeto “data” dado que la primera columna de la original es de tipo carácter o string y tiene por nombre “Provincia”, tal y como se visualiza en la previa y primera salida en la consola de R.

```
# Per calcular r
x <- data[,2:9] #Extreure a data() les dades numèriques i
guardar en l'objecte x
print(x)
```

```
# A tibble: 50 × 8
  `AV. MAQ CONSTR` `EQ. ELEC.` INCEND. MONT. MULT. `IND. ROBO`
      <dbl>          <dbl>    <dbl> <dbl> <dbl>    <dbl>
1         0.59         0.45     2.13  0.87  0.44     0.87
2         0.88         0.4      0     0.48  0.22     0.82
3         2.24         4.12     1.7   3.44  1.11     3.99
4         0.58         0.99     1.28  0.53  3.1      1.49
5         2.41         1.86     1.49  0.59  0        2.2
6         0.23         0.06     0.32  0.02  0.22     0.4
7         1.6         0.51     1.17  1.07  6.64     1.3
8         7.68        20.3     28.2  5.29  18.1     13.1
9         1.25         0.34     0.43  0.28  0.88     0.94
10        0.35         0.48     0.11  0.3   0.22     0.9
# 40 more rows
# 2 more variables: `TR. CASCOS` <dbl>, `TR. MERC.` <dbl>
# Use `print(n = ...)` to see more rows
```

Usando la función cor(), hemos calculado la matriz de correlaciones para nuestra matriz x. La importancia de esta etapa no puede ser subestimada, ya que la decisión de continuar con el análisis depende en gran medida de los resultados obtenidos aquí. Específicamente, si encontramos correlaciones significativas entre las covarianzas de las variables, procederemos con el análisis.

La matriz de correlaciones proporciona una visión integral de las relaciones entre nuestras 8 variables. Los valores de correlación oscilan entre -1 y 1. Un valor de -1 indica una correlación negativa perfecta, lo que significa que a medida que una variable aumenta, la otra disminuye en la misma proporción. Un valor de 1 indica una correlación positiva perfecta, lo que significa que las variables se mueven en la misma dirección a la misma proporción. Un valor nulo, por otro lado, indica la ausencia de cualquier correlación entre las variables.

Un aspecto notable de la matriz es que todas las variables están perfectamente correlacionadas consigo mismas. Esto se ve claramente en la diagonal de la matriz,

donde cada variable tiene una correlación unitaria con ella misma. En general, es una regla que una variable siempre tiene una correlación perfecta con ella misma. Esta matriz nos permitirá identificar y comprender las correlaciones significativas entre las diferentes variables, lo que guiará los próximos pasos de nuestro análisis.

```
> r <- cor(x) #Calcular la matriz de correlaciones r d'x
> print(r)
```

```

          AV. MAQ CONSTR EQ. ELEC.  INCEND.  MONT.  MULT. IND. ROBO TR. CASCOS TR. MERC.
AV. MAQ CONSTR 1.0000000 0.8100022 0.7911579 0.9093441 0.5378341 0.8439464 0.8614200 0.9488942
EQ. ELEC.      0.8100022 1.0000000 0.9676326 0.6797119 0.7357510 0.9830908 0.5981057 0.8618763
INCEND.        0.7911579 0.9676326 1.0000000 0.6821279 0.7569510 0.9485580 0.6111071 0.8603902
MONT.          0.9093441 0.6797119 0.6821279 1.0000000 0.4234229 0.6941191 0.9892544 0.9461986
MULT.          0.5378341 0.7357510 0.7569510 0.4234229 1.0000000 0.7107402 0.3652137 0.5871004
IND. ROBO      0.8439464 0.9830908 0.9485580 0.6941191 0.7107402 1.0000000 0.6037594 0.8659776
TR. CASCOS     0.8614200 0.5981057 0.6111071 0.9892544 0.3652137 0.6037594 1.0000000 0.9109179
TR. MERC.      0.9488942 0.8618763 0.8603902 0.9461986 0.5871004 0.8659776 0.9109179 1.0000000

```

La librería “corrplot” muestra de manera gráfica y visual dichas correlaciones:

```
> install.packages("corrplot")
> library("corrplot")
> corrplot(r, method = "number")
#Gràfic de correlacions
```



Breves consideraciones sobre esta matriz:

- La variable relativa a **Averías en la maquinaria de construcción** tiene una correlación muy alta con **Transporte de mercaderías** (concretamente del 0.9488942), lo que sugiere que cuando uno aumenta, el otro también tiende a hacerlo.
- Los siniestros que ocurren en **Equipos eléctricos** están fuertemente correlacionados del 0.9830908 con los de la variable del índice de robo.
- La correlación entre **Montaje** y **Transporte de cascós** es extremadamente alta (0.9892544), casi 1, lo que sugiere que están muy fuertemente relacionadas. De momento, la que tiene mayor correlación en respecto de las anteriores.
- Los siniestros **Multirriesgo**, que incluyen los que tienen lugar en los hogares a parte de los que suceden en industrias, parece ser la variable con las correlaciones más bajas en general, especialmente con **Transporte de casos** (0.3652137) y **Montaje** (0.4234229).

Para profundizar en el análisis, se relevan posibles causas de la razón por la que las variables que influyen en los siniestros industriales parecen no relacionarse al menos de forma lineal con los siniestros Multirriesgo.

En el marco teórico se plantearon dos tipos de siniestralidades que suponen un problema ya sea por cantidades ingentes de siniestros como en términos de coste que tienen que cubrir las entidades proveedoras del servicio de dicha cobertura. Como se ha visto en la primera parte de este proyecto, los siniestros industriales, laborales, catastróficos, climáticos son de tipo multirriesgo porque afectan a distintas variedades de cosas y bienes sociales o materiales. Es por ello que la baja correlación que presenta en relación a las variables más concretamente industriales podría explicarse por disparidades en los factores de riesgo que influyen en su caso y el de los otros porque tienen diferentes factores de riesgo.

Es posible que los siniestros Multirriesgo, que ocurren tanto en hogares como en industrias, sean causados por más factores de riesgo en comparación con los siniestros que ocurren durante el transporte de casos y el montaje. Por eso, los factores de riesgo que explican los siniestros Multirriesgo pueden no tener una relación fuerte con los riesgos que suelen incidir en un ámbito más industrial o laboral, lo que resulta en correlaciones más bajas.

Por otro lado, las condiciones a las que se encuentra el trabajador asegurado por una cobertura multirriesgo que paga su empresa pueden ser diversas a la de una particular que contrata un seguro para que le cubra la reconstrucción de su hogar si un incendio ocurriera, por ejemplo.

Para proseguir con el análisis planteado, se carga la librería "psych" para poder identificar las variables latentes del conjunto de datos y validarlas mediante pruebas o gráficos para visualizar.

```
install.packages("psych") #Llibreria necessària per l'AFE
library(psych)
```

El índice Kaiser-Meyer-Olkin (KMO) es una medida de adecuación de la muestra para el análisis factorial que compara la magnitud de las correlaciones observadas con la magnitud de las correlaciones parciales y sirve, una vez más, para validar la idoneidad del conjunto de datos dado para realizar el análisis. Se suele calcular sobre la matriz de correlaciones tanto globalmente como para cada ítem o variable individual. Los valores individuales de adecuación muestran qué variables contribuyen más o menos a la estructura de correlación global, dado que se calcula el KMO para la matriz de correlaciones de las variables.

Su rango en el cálculo va del intervalo 0 a 1, como si de una probabilidad de tratase, pero aquí los valores más cercanos a la unidad se traducen en una mayor adecuación de los datos. En otras palabras, los datos serán más adecuados para aquellas variables cuyas correlaciones sean próximas a 1, que significará la retención máxima de la varianza contenida en los datos. En efecto:

- Un valor cercano a 1 indica una mayor adecuación de los datos, lo que significa que las variables están correlacionadas de manera significativa y se puede realizar un análisis factorial válido.

- Un valor cercano a 0 indica que las variables no están correlacionadas o están correlacionadas de manera muy débil, lo que dificulta el análisis factorial.

Por lo tanto, el KMO evalúa la proporción de varianza compartida entre las variables observadas en comparación con la proporción de varianza que podría ser compartida si las variables estuvieran perfectamente correlacionadas.

El objetivo de aplicar este índice consiste en reducir el número de variables de la matriz de datos original exportada. Dicha reducción significa agrupar aquellas variables con rasgos de correlación significativos, es decir, conseguir la dimensión más pequeña posible de la matriz inicial. La dimensión para los objetos que se han creado hasta este punto del proyecto han sido:

```
> dim(data)
[1] 50  9
> dim(x)
[1] 50  8
> dim(r)
[1] 8  8
```

La dimensión que interesa reducir es la de la matriz cuantitativa “x”, por tanto, reducir las columnas de 8 a un número menor, el cual será justamente el número de factores latentes o subyacentes derivados del análisis. Cabe decir que cuando se nos es dicho “reducir la dimensionalidad” puede llevarse a confusión y querer disminuir el número de filas, por tanto, el número de ítems o casos (las provincias). Eso, sin embargo, no es posible por dos razones: (1) las reglas de adecuación de la muestra piden un mínimo de casos para la realización de dicho análisis y (2) no sería de interés porque se estaría quitando de en medio una provincia potencial de ser analizada y arrojar datos sobre ella. Este error provocaría que el analista se alejara del rigor y exactitud, lo cual hay que evitar teniendo presentes el sentido común y el ser críticos en todo momento. El índice KMO ya definido es uno de los criterios cuantitativos para decidir la cantidad de factores a retener en un análisis de estas características.

```
#Decidir n° factors a retindre per reduir la dimensionalitat
de les variables en base a dos criteris:
```

```
#Crit. quantitatiu_1
#Kaiser-Meyer-Olkin factor adequacy
```

```
> KMO(r) #Overall MSA = 0.84, les dades són adequades per
l'anàlisi
Kaiser-Meyer-Olkin factor adequacy
Call: KMO(r = r)
Overall MSA = 0.84
```

MSA for each item =

1) Avería de maquinaria	5) Multirriesgo industrial
2) Equipos electrónicos	6) Índice de Robos
3) Incendios industriales	7) Transportes cascos
4) Montaje	8) Transportes mercaderías

AV. MAQ	CONSTR	EQ. ELEC.	INCEND.	MONT.
	0.92	0.86	0.93	0.77
	MULT.	IND. ROBO	TR. CASCOS	TR. MERC.
	0.96	0.78	0.70	0.8

Se muestra el resultado del cálculo del KMO para una matriz de datos. El valor global del KMO es de 0.84, lo que indica que los datos son adecuados para el análisis factorial. Esto significa que la correlación entre las variables incluidas en la matriz es lo suficientemente fuerte como para realizar un análisis factorial significativo. Además del valor global del KMO, también se proporciona el KMO para cada ítem o variable individual dentro de la matriz. Se muestran los valores del KMO para las 8 variables diferentes, que representan diferentes aspectos o categorías relacionadas con un estudio específico. Estos valores oscilan entre 0.70 y 0.96, lo que indica que todas las variables tienen una adecuada correlación dentro de la matriz.

La interpretación adicional menciona la relación de correlaciones parciales dentro del 84% global:

- Se destaca un grupo de variables (Multirriesgo, Incendios industriales, Averías en maquinarias de construcción) que muestran una alta correlación entre sí, con una correlación superior a 0.9.
- Luego, hay otro grupo de variables (Transporte de mercaderías y Equipos eléctricos) que están ligeramente por debajo del primer grupo en términos de correlación.
- Finalmente, se menciona otro grupo de variables (Transporte de cascos, Montaje e Índice de Robos) que tienen correlaciones en el rango de 0.7 a 0.8.

En resumen, el análisis indica que los datos son adecuados para realizar un análisis factorial, y se identifican las variables que tienen una mayor influencia en la correlación global, siendo aquellas que forman el primer grupo mencionado. Este tipo de análisis puede ser útil para comprender qué variables están más estrechamente relacionadas entre sí y cómo contribuyen al análisis general.

Esta parte supone la identificación de las variables que más influyen en la correlación global, que son las variables que forman el primer grupo definido. A continuación, se plantea el segundo criterio cuantitativo consistente en evaluar los valores y vectores propios de la matriz de "r", matriz de correlaciones de "x". La función "eigen()" se encarga de calcular los valores y vectores propios para una matriz de correlaciones o para una matriz de varianzas y covarianzas.

El análisis calcula dos valores propios sobre la matriz de correlaciones y no sobre la de varianzas y covarianzas por los motivos que siguen:

- La naturaleza de los datos: La tipología de variables cuya intrínseca siniestralidad industrial es objeto de análisis en las 50 provincias tienen diferentes unidades de medida, a lo la matriz de correlación sea más idónea en un contexto de naturaleza heterogénea que se muestra a continuación.

<b>VARIABLE DE SINIESTRALIDAD</b>	<b>UNIDAD DE MEDIDA</b>
Avería de maquinaria	Número de incidentes o tiempo perdido (días/horas)
Equipos electrónicos	Número de fallas o tiempo de inactividad (días/horas)
Incendios industriales	Número de incendios o área afectada (metros cuadrados)
Montaje	Número de errores o retrasos en el proceso de montaje
Multirriesgo industrial	Medida compuesta que puede variar según la metodología utilizada
Índice de Robos	Número de robos o valor monetario de los robos
Transportes cascos	Número de accidentes de transporte o lesiones reportadas
Transportes mercaderías	Volumen de mercancías transportadas o valor monetario de las mercancías transportadas

- Los objetos del análisis: La matriz de correlaciones se utiliza para calcular los coeficientes de correlación entre las variables, lo cual permite comparar la fuerza y la dirección de las relaciones entre ellas sin verse afectadas por las diferencias en las unidades de medida y las escalas.

En efecto, los valores propios representan la cantidad de varianza explicada por cada factor, mientras que los vectores propios representan las combinaciones lineales de las variables originales que conforman cada factor.

La matriz de correlaciones ajusta los coeficientes para eliminar las diferencias en las unidades y escalas, dados los porcentajes con distintas unidades subyacentes que representan las variables.

```
> #Crit. quantitativ_2
> #Eigenvalues>1
> val <- eigen(r)
> val$values # 2 variables a retindre
```



```
[1] 6.421891901 1.090040106 0.326549127 0.102297670
0.036618441 0.012153597 0.008387216 0.002061942
```


Se da más énfasis sobre todo en los valores propios. Se deseará retener los factores principales, entendidos como valores propios, que explican la mayor parte de la varianza en los datos en la medida que estos superen el valor 1 (en efecto, dos valores propios: 6.421891901 y 1.090040106).

Como conclusión, se retienen dos factores latentes y se logra reducir la dimensionalidad del conjunto inicial con éxito.

La elección se corrobora en el gráfico “Scree plot” o sedimentación:

```
#Crit. gràfic/visual: Gràfic de sedimentació (o Scree plot)
```

```
> plot(val$values, type="b", pch=19, xlab="Valores
Propios", ylab="Valor", main="Gráfico de Sedimentación", col=3)
> abline(a=1, b=0, col="blue") #2 variables retindr  (ok)
```



El corte o punto de inflexión se produce en el momento que la línea punteada de color verde, que contiene los distintos valores propios obtenidos de la función anterior “eigen()” sobre la matriz de correlaciones, se cruza con la línea azul, la cual indica la ordenada horizontal del valor unitario. La intersección indica el último punto o valor propio y, por tanto, poder considerar el recuento numérico de los valores propios acumulados a tener en cuenta. Dicha acumulación resulta en seleccionar 2 valores.

A partir de aquí se da paso a la realización del Análisis Factorial en sí. La función utilizada, principal(), estiman las 8 variables de estudio mediante la técnica de los Componentes Principales. La técnica de Componentes Principales y del Análisis Factorial suelen confundirse porque sus semejanzas. Se parece por su necesaria ortogonalidad y linealidad en la adecuación de sus datos, por ejemplo. Sin embargo, se diferencian en la forma de interpretar los datos obtenidos. En Componentes Principales son las variables quienes definen a sus factores pero en Análisis Factorial son los factores quienes definen a las variables de estudio, véase en los diagramas diagram(fac0, e.size = 0.1) y (fac1, e.size = 0.1) luego de aplicar la función principal.

```
> library(psych) #volver a cargar, a veces se desactiva sola
> fac0 <- principal(x, nfactors = 2, rotate = "none", scores = 2)
> print(fac0)
```

Principal Components Analysis

```
Call: principal(r = x, nfactors = 2, rotate = "none", scores = 2)
```

Standardized loadings (pattern matrix) based upon correlation matrix

	<b>PC1</b>	<b>PC2</b>	<b>h2</b>	u2	com
AV. MAQ CONSTR	<b>0.94</b>	<b>-0.20</b>	<b>0.93</b>	0.0716	1.1
EQ. ELEC.	<b>0.93</b>	<b>0.30</b>	<b>0.96</b>	0.0446	1.2
INCEND.	<b>0.93</b>	<b>0.30</b>	<b>0.95</b>	0.0522	1.2
MONT.	<b>0.89</b>	<b>-0.44</b>	<b>0.99</b>	0.0143	1.5
MULT.	<b>0.70</b>	<b>0.55</b>	<b>0.79</b>	0.2077	1.9
IND. ROBO	<b>0.93</b>	<b>0.27</b>	<b>0.94</b>	0.0585	1.2
TR. CASCOS	<b>0.83</b>	<b>-0.52</b>	<b>0.97</b>	0.0306	1.7
TR. MERC.	<b>0.98</b>	<b>-0.18</b>	<b>0.99</b>	0.0085	1.1

La columna "h2" obtenida de la función "factorial" muestra las comunalidades en términos de varianza explicada contenida en los datos. Por lo que un valor de h2 mayor a 0.9 ya indica que las variables están influenciadas principalmente por un único factor PC1. Las columnas "PC1" y "PC2" también muestran las mismas conclusiones que con las comunalidades pero de otra manera. La comparación de los altos valores en varianza que las variables retienen en PC1 y bajos valores en PC2, segundo factor, se traduce en una influencia significativa para el primer factor.

	<b>PC1</b>	<b>PC2</b>
SS loadings	6.42	1.09
Proportion Var	<b>0.80</b>	0.14
Cumulative Var	0.80	<b>0.94</b>
Proportion Explained	<b>0.85</b>	0.15
Cumulative Proportion	0.85	<b>1.00</b>

Mean item complexity = 1.3

Test of the hypothesis that 2 components are sufficient.

The root mean square of the residuals (RMSR) is 0.03  
with the empirical chi square 3.05 with prob < 1

Fit based upon off diagonal values = 1

Adicionalmente, el primer factor explica una proporción significativamente mayor de la varianza y varianza explicada en comparación con el segundo factor. Esta proporción es muy significativa e importante para el análisis, ya que influye en la interpretabilidad posterior de las variables. Sin embargo, en términos acumulativos, el segundo factor no se aleja lo suficiente como para destacar claramente frente al primer factor. Además, la varianza acumulada explicada por el segundo factor es insignificante respecto con la retención de varianza anterior. Esto significa que el segundo factor no aporta información adicional significativa, al contrario que el primer factor. La contribución del primer factor será importante para comprender la siniestralidad industrial porque explica una proporción sustancial de la varianza y

varianza explicada. Por su parte, la contribución del segundo factor es baja o inexistente.

```
> diagram(fac0, e.size = 0.1)
```

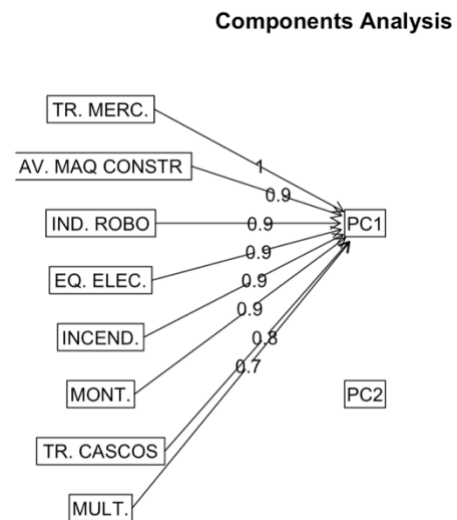
El resultado derivado del objeto “fac0” ha sido un intento fallido de repartir las variables a factores, por lo que no es válido. Tal y como muestra el diagrama de la derecha, no se ha producido ningún repartimiento entre los factores elegidos, lo cual replantea el volver a formular el proceso de factorización para llegar al objetivo.

Aunque sin tener que rotar ya se cumpla la propiedad de la ortogonalidad, entendida como la propiedad de los factores incorrelacionados u ortogonales entre sí, la falta de rotación puede conducir a la **consideración de un único factor al cual se le atribuye la mayor varianza explicada en los datos**, lo que resulta en un patrón difuso y poco claro.

Para obtener una interpretación significativa concorde al objetivo de identificar los factores subyacentes que expliquen la estructura de correlaciones entre las variables, es necesario realizar una rotación de factores después del análisis previo.

Uno de los métodos de rotación que resulta en factores ortogonales es la rotación Varimax, en donde la independencia factorial en la rotación pretende simplificar la interpretación de los resultados.

La similitud entre no rotar y la rotación ortogonal Varimax es que ambas sugieren una alta correlación general entre variables y una fuente común compartida de variabilidad. Sin embargo, las variables rotadas presentan **correlaciones muy altas únicamente en uno de los factores considerados**. Así, se lleva a cabo una redistribución clara y comprensible de la varianza explicada entre las variables asignándoles el factor les que corresponda.



La rotación Varimax se ha llevado a cabo para diferenciar las variables y clasificarlas en el factor subyacente que mejor las representa. La diferenciación de las características de las 8 variables y su respectiva clasificación en el factor subyacente que les corresponde en términos de influencia o correspondencia de naturaleza similar se realiza mediante la rotación Varimax, que es una rotación ortogonal. Esto no significa que no se acepten otros métodos de rotación (por ejemplo, oblicua), pues se elige arbitrariamente aquella rotación cuya información se pueda interpretar de la mejor manera, es decir, la que sea capaz de mostrar los datos de la forma más clara, numérica y visual.

```
> diagram(fac1, e.size = 0.1) #obtenció de les variables factoritzades
```

```
> fac1 <- principal(x,nfactors = 2,rotate = "varimax", score = 2)
```

```
> print(fac1)
```

Principal Components Analysis

Call: principal(r = x, nfactors = 2, rotate = "varimax", scores = 2)

Standardized loadings (pattern matrix) based upon correlation matrix

	RC1	RC2	h2	u2	com
AV. MAQ CONSTR	<b>0.82</b>	0.51	0.93	0.0716	1.7
EQ. ELEC.	0.46	<b>0.86</b>	0.96	0.0446	1.5
INCEND.	0.46	<b>0.86</b>	0.95	0.0522	1.5
MONT.	<b>0.95</b>	0.30	0.99	0.0143	1.2
MULT.	0.12	<b>0.88</b>	0.79	0.2077	1.0
IND. ROBO	0.48	<b>0.84</b>	0.94	0.0585	1.6
TR. CASCOS	<b>0.96</b>	0.21	0.97	0.0306	1.1
TR. MERC.	<b>0.83</b>	0.56	0.99	0.0085	1.8

#Vectores importantes para el análisis

```
> fac1$scores[,1]
```

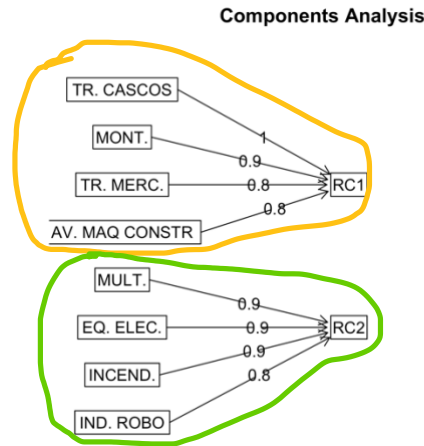
```
[1] -0.10294482 -0.04853254 0.01759564 -0.32340976 0.01222912  
[6] -0.12064083 -0.49543175 -1.40041892 -0.05620572 -0.11096979  
[11] 0.02995401 -0.08827880 0.00316150 -0.17654297 -0.47810875  
[16] -0.10914443 -0.07491766 -0.12786723 -0.05927627 -0.18894124  
[21] -0.01852697 -0.83117258 0.04689052 -0.06641180 0.02046729  
[26] -0.08372824 0.17907225 -0.13542564 -0.68291836 -0.02318742  
[31] 6.67827995 -0.08496405 -0.20958806 -0.12594965 -0.05697183  
[36] -0.12573825 -0.02181941 0.02480850 -0.16786354 -0.10885505  
[41] 0.34789167 -0.11400773 -0.15282298 -0.13471180 -0.03527694  
[46] 0.29209256 -0.04685649 -0.26128532 -0.12903880 -0.07369066
```

```
> round(fac1$scores[,2],8)
```

```
[1] -0.36113201 -0.51731467 0.25033254 0.05473701 -0.20612539  
[6] -0.55327930 0.42227957 6.21746781 -0.39728511 -0.48488334  
[11] -0.17152448 -0.14503056 -0.36742251 -0.32565385 0.44139135  
[16] -0.50885495 0.00483329 -0.13280591 -0.57233781 -0.02350477  
[21] -0.44929022 0.73221513 -0.21886319 -0.38797328 -0.11715019  
[26] -0.49598416 -0.41156759 -0.34886145 0.63580979 -0.48529804  
[31] 1.37647701 0.40085100 0.43488137 -0.04340838 -0.56474978  
[36] -0.48446803 -0.17689797 -0.43757400 -0.36337940 -0.52338478  
[41] 0.14218833 -0.56568397 -0.08338957 -0.52068263 -0.34931004  
[46] 1.02033218 -0.34246649 0.36990703 -0.50725342 0.14108783
```

## 4. Resultados y conclusión

### 4.1. Significación de los factores subyacentes



*Elaboración propia con R. Diagrama derivado del Análisis Factorial. Reparto de variables hacia factores (en realidad, de factores hacia variables).*

En las flechas se indica la varianza retenida por cada una para explicar el factor. Como se trata de un Análisis Factorial, las flechas deberían tener la dirección opuesta a la mostrada en el diagrama de distribución.

1) Avería de maquinaria	5) Multirriesgo industrial
2) Equipos electrónicos	6) Índice de Robos
3) Incendios industriales	7) Transportes cascos
4) Montaje	8) Transportes mercaderías

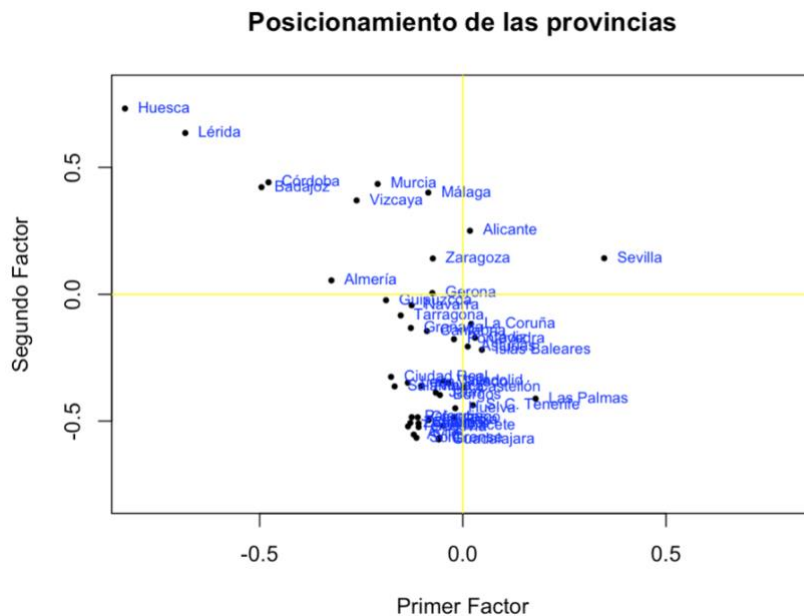
Recuperando la tabla de las variables consideradas en el análisis y como conclusión del Análisis Factorial realizado, se han resaltado en verde aquellas que forman el primer factor RC1 y en naranja aquellas que forman el segundo factor RC2. El acrónimo RC se refiere a que se ha realizado una rotación "Varimax" utilizando la técnica de Componentes Principales, que es la técnica por defecto de la función. Seguidamente se obtienen las interpretaciones de grupos factoriales obtenidos:

- El primer factor latente (Avería de maquinaria, montaje, transportes cascos, transportes mercaderías) tiene que ver con aquellos **sucesos que están directamente relacionados con el funcionamiento operativo** de las empresas, incluyendo problemas de equipamiento y logística, que pueden interrumpir las operaciones diarias y causar retrasos o pérdidas de producción.
- El segundo factor latente (equipos electrónicos, incendios industriales, multirriesgo industrial, índice de robos) se refiere a los **incidentes más graves y menos predecibles que pueden poner en peligro la seguridad** de los trabajadores, el inventario y la infraestructura, e incluso la viabilidad a

largo plazo de la empresa. Estos sucesos requieren una gestión de riesgos más sofisticada y a menudo implican mayores costes de recuperación.

La instrucción plot() en R permite el dibujo de un gráfico de dos ejes. En este caso, representa la afectación simultánea que tienen los dos factores en los 50 casos (provincias).

```
#Gràfic de dispersió de les províncies espanyoles
> plot(fac1$scores[,1], fac1$scores[,2], xlab = "Primer
Factor", ylab = "Segundo Factor",
+      main = "Posicionamiento de las provincias", pch = 19,
cex = 0.5,
+      xlim = c(-0.8, 0.8), ylim = c(-0.8, 0.8))
> labels <- data$Provincia
> text(fac1$scores[,1], fac1$scores[,2], labels, cex = 0.7, pos
= 4, col = "blue")
> abline(v = mean(fac1$scores[,1]), col = "yellow")
> abline(h = mean(fac1$scores[,2]), col = "yellow")
```



*Elaboración propia con R. Posición relativa de las 50 provincias españolas respecto las puntuaciones factoriales RC1 y RC2.*

```
#dades grafic posicionament
data_con_factores <- cbind(Provincia = data$Provincia,
+                          Factor_1 = round(fac1$scores[,1],4),
+                          Factor_2 = round(fac1$scores[,2],4))
print(data_con_factores)
# Variables más relacionadas con el Factor_1 y con el Factor_2
variables_factor1 <- c("TR.CASCOS", "MONT.", "TR.MERC.", "AV.MAQ
CONSTR")
variables_factor2 <- c("MULT.", "EQ.ELEC.", "INCEND.", "IND.ROBO")
```

A parte de poder extraer rápidamente la conclusión de forma global, el gráfico de dispersión previo también permite clasificar las provincias en tres grupos:

- Provincias cuya contribución del primer factor es alta: En las provincias de este grupo ocurren siniestros de carácter meramente operativo. Ej. Sevilla.
- Provincias cuya contribución del segundo factor es alta: Provincias en donde son comunes los siniestros menos predecible, que dependen de hechos más bien aleatorios y difíciles de controlar por humanos.
- Provincias próximas al centro del mapa: Es el grupo más notablemente numeroso. Incluye la mayoría de las provincias de la Península Ibérica, incluidas las Islas Canarias y Baleares. De forma generalizada, el primer factor les afecta de manera menos significativa que el segundo factor, el cual es más variable entre esta mayoría. Las Islas, tanto las Canarias como Baleares muestran una inclinación mayor respecto las provincias peninsulares. No cabe duda que estas provincias se diferencian entre ellas por tener un diferente grado o incidencia de la siniestralidad industriales por motivos mucho más aleatorios, por ejemplo, por los catastróficos.

Por lo tanto, sin obviar el carácter heterocedástico que se observa en el gráfico de dispersión de la derecha, lo más destacado es que Sevilla es la provincia española con mayor contribución en los contratiempos industriales y en catastróficos o de carácter no necesariamente ligado al funcionamiento operativo en Huesca (Aragón).

#### 4.2. Afectaciones factoriales en las provincias españolas

A continuación, se muestran dos mapas en los cuales se aprecian los territorios españoles geográficamente delimitados de manera aún más gráfica. Se complementan interpretaciones anteriores para los factores obtenidos del Análisis Factorial, esta vez por separado. Se pretende vislumbrar las provincias principalmente afectadas en España en base a las siguientes puntuaciones factoriales (conocidas como scores) obtenidas del análisis mediante R:

nº	Provincia	Factor 1	Factor 2	nº	Provincia	Factor 1	Factor 2
1	Álava	-0.1029	-0.3611	26	La Rioja	-0.0837	-0.496
2	Albacete	-0.0485	-0.5173	27	Las Palmas	0.1791	-0.4116
3	Alicante	0.0176	0.2503	28	León	-0.1354	-0.3489
4	Almería	-0.3234	0.0547	29	Lérida	-0.6829	0.6358
5	Asturias	0.0122	-0.2061	30	Lugo	-0.0232	-0.4853
6	Ávila	-0.1206	-0.5533	31	Madrid	6.6783	1.3765
7	Badajoz	-0.4954	0.4223	32	Málaga	-0.085	0.4009
8	Barcelona	-1.4004	6.2175	33	Murcia	-0.2096	0.4349
9	Burgos	-0.0562	-0.3973	34	Navarra	-0.1259	-0.0434
10	Cáceres	-0.111	-0.4849	35	Orense	-0.057	-0.5647
11	Cádiz	0.03	-0.1715	36	Palencia	-0.1257	-0.4845
12	Cantabria	-0.0883	-0.145	37	Pontevedra	-0.0218	-0.1769
13	Castellón	0.0032	-0.3674	38	S. C. Tenerife	0.0248	-0.4376
14	Ciudad Real	-0.1765	-0.3257	39	Salamanca	-0.1679	-0.3634
15	Córdoba	-0.4781	0.4414	40	Segovia	-0.1089	-0.5234
16	Cuenca	-0.1091	-0.5089	41	Sevilla	0.3479	0.1422
17	Gerona	-0.0749	0.0048	42	Soria	-0.114	-0.5657
18	Granada	-0.1279	-0.1328	43	Tarragona	-0.1528	-0.0834
19	Guadalajara	-0.0593	-0.5723	44	Teruel	-0.1347	-0.5207
20	Guipúzcoa	-0.1889	-0.0235	45	Toledo	-0.0353	-0.3493
21	Huelva	-0.0185	-0.4493	46	Valencia	0.2921	1.0203
22	Huesca	-0.8312	0.7322	47	Valladolid	-0.0469	-0.3425
23	I. Baleares	0.0469	-0.2189	48	Vizcaya	-0.2613	0.3699
24	Jaén	-0.0664	-0.388	49	Zamora	-0.129	-0.5073
25	La Coruña	0.0205	-0.1172	50	Zaragoza	-0.0737	0.1411

#### 4.2.1. Afectaciones del primer factor subyacente

Teniendo en cuenta que el primer factor abarca aquellos sucesos que están directamente relacionados con el **funcionamiento operativo de las empresas**, incluyendo problemas de equipamiento y logística, que pueden interrumpir las operaciones diarias y causar retrasos o pérdidas de producción.

Esto podría indicar que estas provincias tienen una mayor incidencia de sucesos relacionados con problemas del día a día fruto del trabajo en las empresas, como averías en maquinaria, problemas en el montaje o transporte de mercaderías. Apuntar la influencia de este tipo de siniestros en empresas industriales y su relación intrínseca, por ende, con la siniestralidad laboral de estas. En base a los scores o puntuaciones factoriales obtenidas del Análisis previo, podemos observar que las presentes provincias presentan valores en riesgos operativos en lugar estratégicos y dispersos. En primer lugar, en el noreste peninsular destacan La Coruña y Asturias con valores más altos en este primer factor latente, también el Este valenciano y Alicante. En segundo lugar, las Islas (tanto las Canarias como Baleares) han padecido en los recientes años de siniestros relativos a la actividad más laboral y previsible. Madrid supone una provincia importante para tomar medidas preventivas y una gestión de siniestros adecuada a causa de su densidad poblacional y la intensidad en materia de riesgos en el sector constructor o laboral. Por último, las provincias andaluzas de Sevilla y Cádiz también apuntan a altos índices de incidencia por elevadas tasas de siniestralidad industriales.

Contribuciones del primer factor por provincia



Elaboración propia con R



#### 4.2.2. Afectaciones del segundo factor subyacente

El segundo factor, por su parte, abarca aquellos **incidentes más graves y menos predecibles** que pueden poner en peligro la seguridad de los trabajadores, el inventario y la infraestructura, e incluso la viabilidad a largo plazo de la empresa. Estos sucesos requieren una gestión de riesgos más sofisticada y a menudo implican mayores costes de recuperación.

Durante el período del 2017-2021 las provincias de Lérida, Barcelona y Gerona presentan más siniestros que son ajenos al control directo de la empresa aseguradora que relacionados con la actividad corriente de ésta.

Esto podría explicar que Catalunya, y más en concreto, Barcelona sea una de las provincias con altos costes, tal y como se ha analizado previamente en el marco teórico para los costes a desembolsar para cubrir los desperfectos en el territorio catalán. Además, podría tener cierta correlación con ser una de las provincias españolas con mayor densidad poblacional. La comunidad aragonesa y la provincia vizcaína también aparecen sombreadas.

Por otro lado, las provincias de Valencia, Murcia y alrededores tienen un peso mayor de siniestros de carácter más ajeno a la actividad que del anterior factor.

Si bien en la mayoría de los territorios andaluces están presentes afectaciones por este tipo de riesgos junto con la comunidad madrileña, comparten asimismo riesgos del otro tipo de riesgo del primer factor mencionados previamente.

#### Contribuciones del segundo factor por provincia



Elaboración propia con R

## IV.II. CASO PRÁCTICO 2 (SINIESTRALIDAD METEOROLÓGICA)

### 1. Descripción de la base de datos técnica

La patronal UNESPA cede la siguiente información en su informe “EL SEGURO Y LA SOSTENIBILIDAD CLIMÁTICA Siniestralidad meteorológica pagada por las aseguradoras 2017-2021” sobre los siniestros meteorológicos o climáticos que tuvieron lugar en la Península Ibérica e Islas des del período complemplado del año 2017 hasta el 2021:

```
# Número de siniestros anuales
> sin_17 <- 653905
> sin_18 <- 827667
> sin_19 <- 769127
> sin_20 <- 861223
> sin_21 <- 769202
```

Se muestran de forma de forma concatenada, es decir, dentro de un mismo vector para facilitar los cálculos posteriores:

```
> siniestros <- c(sin_17,sin_18,sin_19,sin_20,sin_21)
> print(siniestros)
[1] 653905 827667 769127 861223 769202
```

Además, la patronal también proporciona información cuantitativa en su informe de los costes medios de los siniestros de este tipo cubiertos por los seguros multirriesgo para cada una de las provincias españolas.

Las provisiones a calcular deben estar en unidades monetarias, entonces resulta indispensable tener que calcular la cuantía total de los siniestros o coste total, siendo este el producto de los siniestros estimados y el coste medio por siniestros. Esta operación se realizada de forma anual para cada una de las 50 provincias:

$$\text{Coste total} = \text{Siniestros estimados} \times \text{Coste medio por siniestro}$$

#### 1.1. Obtención estimada del número de siniestros

Se baja el archivo Excel.xlsx con ayuda de la librería “readxl”, utilizada en el anterior caso práctico, para visualizar los datos. Estos datos contienen porcentajes de siniestros repartidos entre las provincias, esta vez dividiendo entre 100 como es debido, para averiguar el número de siniestros por provincia y año del período:

```
> install.packages("readxl")
> library(readxl)
> porcentsin_pro <-
read_excel("Desktop/tfg/porcentsinpro.xlsx")
> print(porcentsin_pro)
```

```

# A tibble: 50 × 6
  PROVINCIA `2017` `2018` `2019` `2020` `2021`
  <chr>      <dbl> <dbl> <dbl> <dbl> <dbl>
1 Álava      0.006  0.0056 0.0038 0.0035 0.0034
2 Albacete   0.0102 0.0064 0.0099 0.0068 0.0116
3 Alicante   0.101  0.0383 0.113  0.0629 0.0388
4 Almería    0.0119 0.0103 0.0111 0.0083 0.008
5 Asturias   0.0194 0.0192 0.0267 0.0189 0.0201
6 Ávila      0.0086 0.007  0.005  0.0057 0.0072
7 Badajoz    0.0079 0.0121 0.0091 0.0091 0.0113
8 Barcelona  0.0994 0.126  0.108  0.159  0.059
9 Burgos     0.008  0.0075 0.0076 0.0097 0.0088
10 Cáceres   0.0061 0.0074 0.0063 0.0066 0.0066
# 40 more rows
# Use `print(n = ...)` to see more rows

```

```

> class(porcentsin_pro)
[1] "tbl_df"      "tbl"        "data.frame"

```

Se seleccionan solamente los datos numéricos de los porcentajes de siniestros por provincia y años del período considerado. El data frame de “porcentsin\_prov” es el mismo que el anterior pero sin considerar la fila carácter “chr” de las provincias.

```

porcentsin_prov <- porcentsin_pro[,2:6]
print(porcentsin_prov)
dim(porcentsin_prov) #[1] 50 5

```

El objeto siguiente es el data frame “sin\_pro”. Este viene determinado por las columnas (período en años de cálculo) con los porcentajes de cada provincia. Tiene que tener las mismas dimensiones que “porcentsin\_prov” para poder multiplicar saliente de los siniestros estimados.

```

sin_pro <- as.data.frame(matrix(0, nrow =
nrow(porcentsin_prov), ncol = ncol(porcentsin_prov))
colnames(sin_pro) <- colnames(porcentsin_prov)
rownames(sin_pro) <- porcentsin_pro$PROVINCIA

print(sin_pro)
dim(sin_pro) #[1] 50 5

# Multiplicar porcentajes por siniestros de cada año
for (i in 1:ncol(porcentsin_prov)) {
  sin_pro[, i] <- porcentsin_prov[, i] * siniestros[i]
}

```

La estimación del número de siniestros redondeado, por ser variable discreta, se visualiza en la salida como sigue:

```
> print(round(sin_pro))
> nrow(round(sin_pro))#[1] 50
```

	2017	2018	2019	2020	2021
Álava	3923	4635	2923	3014	2615
Albacete	6670	5297	7614	5856	8923
Alicante	66044	31700	87142	54171	29845
Almería	7781	8525	8537	7148	6154
Asturias	12686	15891	20536	16277	15461
Ávila	5624	5794	3846	4909	5538
Badajoz	5166	10015	6999	7837	8692
Barcelona	64998	104369	83296	136676	45383
Burgos	5231	6208	5845	8354	6769
Cáceres	3989	6125	4846	5684	5077
Cádiz	19617	23671	8383	10507	12846
Cantabria	10724	14650	20228	17483	14153
Castellón	14713	16636	10768	23425	24614
Ciudad Real	3793	7532	7768	14899	10077
Córdoba	4839	11091	6768	9473	5769
Cuenca	4447	4635	4076	3703	10153
Gerona	13797	17381	14075	22909	6923
Granada	8828	15891	8768	7234	6769
Guadalajara	3400	5959	4461	5942	14461
Guipúzcoa	6147	5049	6922	7837	5154
Huelva	5035	8111	3153	5684	5231
Huesca	4250	6125	3230	4995	5077
Islas Baleares	29622	22181	24612	24286	20461
Jaén	5362	11918	8307	4564	5615
La Coruña	15367	18043	19536	17311	15461
La Rioja	3335	12829	4538	5598	5538
Las Palmas	3858	7532	3000	4392	5000
León	9482	11256	9691	7837	6692
Lérida	5820	6042	5615	9990	5615
Lugo	4839	6125	5615	5856	4384
Madrid	67221	85581	88911	77596	182685
Málaga	18636	34017	13614	19205	20538
Murcia	22429	19781	59607	23253	19153
Navarra	6474	7532	6461	7665	7000
Orense	7912	7366	6307	5167	6692
Palencia	2223	3559	2846	3703	2308
Pontevedra	15040	20361	19459	17397	16384
Salamanca	3139	5297	5768	4564	5538
Santa Cruz de Tenerife	3335	7366	3230	5684	6077
Segovia	4708	6290	3769	4995	5000
Sevilla	12424	26568	15690	12918	13153
Soria	1896	2483	1692	2067	2846

<b>Tarragona</b>	24325	28141	20920	25492	21384
<b>Teruel</b>	3270	3973	1846	4737	4154
<b>Toledo</b>	12555	12994	13152	12746	43614
<b>Valencia</b>	56367	75649	59377	132973	52998
<b>Valladolid</b>	4708	7615	8537	7493	6384
<b>Vizcaya</b>	12490	12167	14383	12660	9692
<b>Zamora</b>	3270	2566	3077	3014	3000
<b>Zaragoza</b>	11770	26568	8999	13952	15153

## 1.2. Obtención del coste medio por siniestro

```
cost_pro <- read_excel("Desktop/tfg/porcentsinpro.xlsx",
                      sheet = "Hoja2")
```

```
# A tibble: 50 × 6
  PROVINCIA `2017` `2018` `2019` `2020` `2021`
  <chr>      <dbl> <dbl> <dbl> <dbl> <dbl>
1 Álava      1492.  1500.  3109.  2955.  786.
2 Albacete   1159.   535.   724.   764.  1235.
3 Alicante  1073.  1129.   907.  1492.  1029.
4 Almería   2687.  4047.  2348.  6421.  1498.
5 Asturias   861.   859.  1214.   970.   661.
6 Ávila      794.   688.   579.   872.   593.
7 Badajoz    524.   747.   663.   551.   343.
8 Barcelona 1104.   873.  1441.  1519.  1360.
9 Burgos     954.   751.  1209.  1468.   739.
10 Cáceres   756.   394.   547.   366.   349.
# 40 more rows
# Use `print(n = ...)` to see more rows
```

```
cost_prov <- cost_pro[,2:6] #columna provincias omitida
coste <- sin_pro * cost_prov
dim(coste) #[1] 50 5
> print(round(coste))
```

	<b>2017</b>	<b>2018</b>	<b>2019</b>	<b>2020</b>	<b>2021</b>
<b>Álava</b>	5854895	6952310	9086065	8908344	2056112
<b>Albacete</b>	7729267	2835150	5516450	4474167	11020748
<b>Alicante</b>	70880176	35800629	78995175	80840357	30707858
<b>Almería</b>	20908497	34499787	20043213	45895132	9219101
<b>Asturias</b>	10922437	13657062	24928686	15791568	10224797
<b>Ávila</b>	4464056	3983147	2225623	4282341	3282523
<b>Badajoz</b>	2704942	7477729	4639044	4321080	2984653
<b>Barcelona</b>	71733266	91082659	120045184	207636949	61732114
<b>Burgos</b>	4988720	4664317	7067280	12263638	5004914
<b>Cáceres</b>	3013953	2416208	2649180	2082360	1770155

<b>Cádiz</b>	10239171	10292744	3202491	4301743	4979754
<b>Cantabria</b>	8383842	10039443	14475590	12922082	8047576
<b>Castellón</b>	9773607	8066349	7797163	16773193	25988936
<b>Ciudad Real</b>	1482167	4218092	7517970	18749696	5671382
<b>Córdoba</b>	2560502	5997760	3263412	5733997	2733186
<b>Cuenca</b>	3326600	3641344	3822415	2149223	8869561
<b>Gerona</b>	29279591	20567988	31721726	32631371	7124549
<b>Granada</b>	10627159	8998872	6895982	6005966	6044291
<b>Guadalajara</b>	2466922	3521114	3063102	3775647	10440551
<b>Guipúzcoa</b>	5321757	3900224	5241724	8304928	3725215
<b>Huelva</b>	2169057	4315287	1533035	2917634	2815513
<b>Huesca</b>	3495472	4681871	2486032	9624196	6151224
<b>I. Baleares</b>	33177709	24115035	30988804	24064996	23533777
<b>Jaén</b>	3587353	7031740	4525088	1302612	2318506
<b>La Coruña</b>	9124633	11940950	11551925	10485020	8283364
<b>La Rioja</b>	4785937	10150434	4660507	9328871	4088173
<b>Las Palmas</b>	2182609	2834205	914427	1488968	1769434
<b>León</b>	9500870	10456963	7165138	6777158	3569543
<b>Lérida</b>	8464949	6764226	12837396	26125238	16655394
<b>Lugo</b>	2996003	5591700	4336963	5207261	3280578
<b>Madrid</b>	48374561	46607286	57655280	36197072	166819241
<b>Málaga</b>	11349688	26877262	9279130	10691191	10779208
<b>Murcia</b>	20189187	15007830	56190650	23120246	20576016
<b>Navarra</b>	10077999	5819874	5066003	7176478	4630957
<b>Orense</b>	5384524	3904474	3308443	2466939	3928840
<b>Palencia</b>	1887829	2575590	1939051	4714878	1058776
<b>Pontevedra</b>	8955909	17337058	15426248	15348765	13591841
<b>Salamanca</b>	2102802	2488351	8175224	5447846	3507377
<b>S. C. Tenerife</b>	1150512	3064575	1079577	2753592	1910695
<b>Segovia</b>	3577274	7163421	4469139	4521259	2413860
<b>Sevilla</b>	8968405	24418751	9583098	5533186	6067905
<b>Soria</b>	1637874	2333847	1053455	1734675	1858127
<b>Tarragona</b>	90885275	49813221	36199990	60601589	55727293
<b>Teruel</b>	3999218	2995969	4297617	13392147	3358010
<b>Toledo</b>	8829538	12353489	10467208	10510944	47124661
<b>Valencia</b>	35385831	41276235	46867735	126140687	40571043
<b>Valladolid</b>	7258879	11048235	13441823	9561358	5076920
<b>Vizcaya</b>	8763443	6936238	9821210	13973957	5087108

<b>Zamora</b>	2918247	1218457	2399369	2939074	1487824
<b>Zaragoza</b>	8175997	27392785	6007679	8317931	16703611

## 2. Hipótesis planteada

En base a lo obtenido hasta el momento y teniendo presente los costes totales (también denominadas cuantías totales) por provincia y año de origen, una supuesta empresa decide afrontar dichas obligaciones mediante una distribución de los pagos, que serán repartidas entre los años de desarrollo. Estos pagos serán, en efecto, las provisiones técnicas correspondientes para cada una de las provincias.

Una entidad aseguradora o, en caso de superar ciertos límites que contempla la DGSFP, por el CCS (Consortio de Compensación de Seguros) elabora una política financiera de riesgos. Al tratarse de siniestros de categoría meteorológica y en muchos casos de carácter catastrófico, probablemente la obligación de cobertura supera los límites de lo establecido y sale a cubrir por el CCS.

La política establece un pago como porcentaje del coste total monetario de los siniestros contabilizados en sus cuentas si estos han tenido lugar durante el período temporal de ocurrencia entre el año 2017 y el año 21, ambos incluidos. La distribución hipotética de reparto para los años de desarrollo es del 90%, 5%, 2%, 0.5% y 2.5% para el último. La empresa que asegura desea liquidar totalmente la obligación contraída en el contrato planteado con el reparto mencionados, que supone una cobertura del 100% para los costes de los siniestros ocurridos durante los años de origen o período de cálculo considerado del cual se ceden los datos.

```
coste <- round(coste); coste
#Pagaments com a % sobre el cost total de cada provincia
hip_pag <- c(0.90, 0.05, 0.02, 0.005, 0.025); hip_pag
```

Se añade una columna numérica para identificar el orden en la lista de provincias y facilitar la elaboración de un posterior menú para seleccionar la provincia deseada:

```
Coste <- cbind(id=c(1:50),coste) ; Coste
dim(Coste) #[1] 50 6
```

## 3. Cálculo de provisiones en R

La base de datos “provisio. RData” se toma del documento “provisio: Área de trabajo en lenguaje R para el cálculo de provisiones técnicas en seguros no de vida con métodos deterministas” en el repositorio digital de la Universitat de Barcelona. Esta área de trabajo incluye una función llamada “ibnrchl”, la cual contiene la metodología descrita para calcular provisiones técnicas a partir de la aproximación del método determinista Chain-Ladder.

```

load("~/Desktop/provisio.RData")
View(ibnrchl)

# Barcelona:
c17 <- hip_pag * Coste[8,2];c17
c18 <- hip_pag[1:4] * Coste[8,3];c18
c19 <- hip_pag[1:3] * Coste[8,4];c19
c20 <- hip_pag[1:2] * Coste[8,5];c20
c21 <- hip_pag[1] * Coste[8,6];c21

ibnrchl(c(c17,c18,c19,c20,c21))

# Burgos:
c017 <- hip_pag * Coste[9,2];c017
c018 <- hip_pag[1:4] * Coste[9,3];c018
c019 <- hip_pag[1:3] * Coste[9,4];c019
c020 <- hip_pag[1:2] * Coste[9,5];c020
c021 <- hip_pag[1] * Coste[9,6];c021

ibnrchl(c(c017,c018,c019,c020,c021))

```

#### 4. Triángulos de desarrollo

Los *run-off triangles* o triángulos de desarrollo a modo de ejemplo para dos provincias que difieren por densidad poblacional y magnitud de riesgos por siniestros meteorológicos, tal y como podrían ser Barcelona (de las provincias más costosas para cubrir) y Burgos (situada en el ecuador, tal y como se muestra un poco más adelante) son:

TRIÁNGULO DE CUANTÍAS						
Provincia: Barcelona		Años de desarrollo				
		1	2	3	4	5
Años de origen	2017	64,559,939 €	3,586,663 €	1,434,665 €	358,666 €	1,793,332 €
	2018	81,974,393 €	4,554,133 €	1,821,653 €	455,413 €	-
	2019	108,040,666 €	6,002,259 €	2,400,904 €	-	-
	2020	186,873,254 €	10,381,847 €	-	-	-
	2021	55,558,903 €	-	-	-	-
TRIÁNGULO DE CUANTÍAS						
Provincia: Burgos		Años de desarrollo				
		1	2	3	4	5
Años de origen	2017	4,489,848 €	249,436 €	99,774 €	24,944 €	124,718 €
	2018	4,197,885 €	233,216 €	93,286 €	23,322 €	-
	2019	6,360,552 €	353,364 €	141,346 €	-	-
	2020	11,037,274 €	613,182 €	-	-	-
	2021	4,504,423 €	-	-	-	-

Adicionalmente, se ha obtenido que la suma de pagos futuros son las provisiones pendientes para hacer frente sube hasta los 22.433.481€ para la capital catalana y 1.442.300€ para la provincia de Burgos.

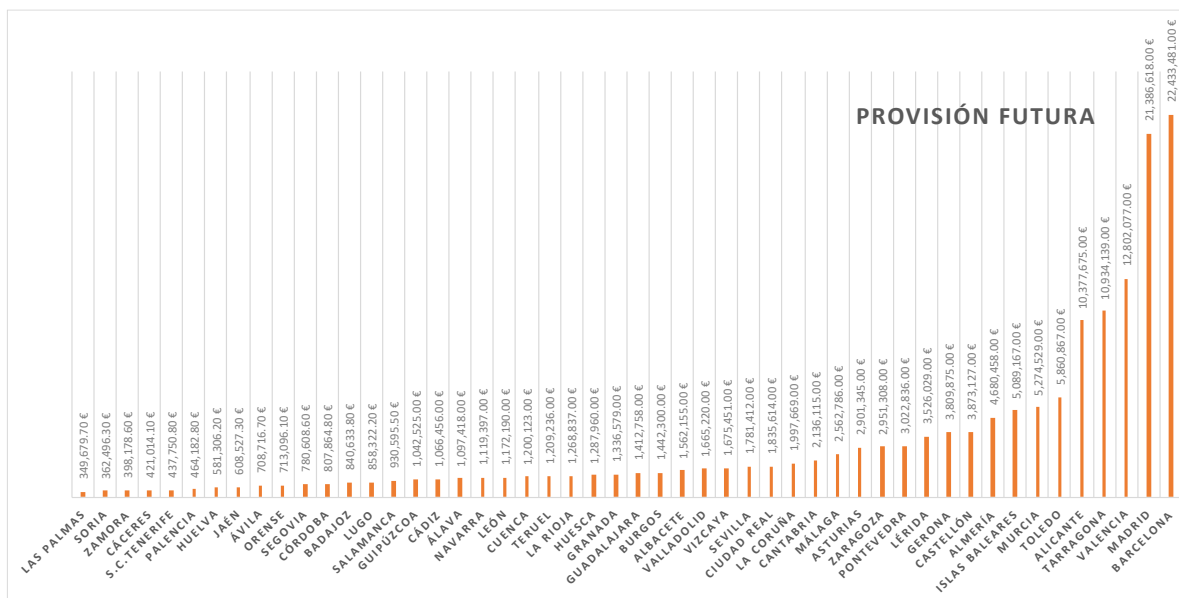


La interpretación conjunta de los triángulos de desarrollo para las provincias de Barcelona y Burgos muestra patrones similares en cuanto a la tendencia en el tiempo y la naturaleza del desarrollo de los siniestros reportados, teniendo influencia sobre estos la distribución de pagos planteada. En ambas provincias, los datos indican un aumento constante en el importe inicial de los siniestros reportados desde 2017 hasta 2020. En particular, 2020 fue el año con el importe más alto de siniestros reportados inicialmente debido al gran coste que supusieron los desperdicios provocados por la borrasca Gloria (enero 2020).

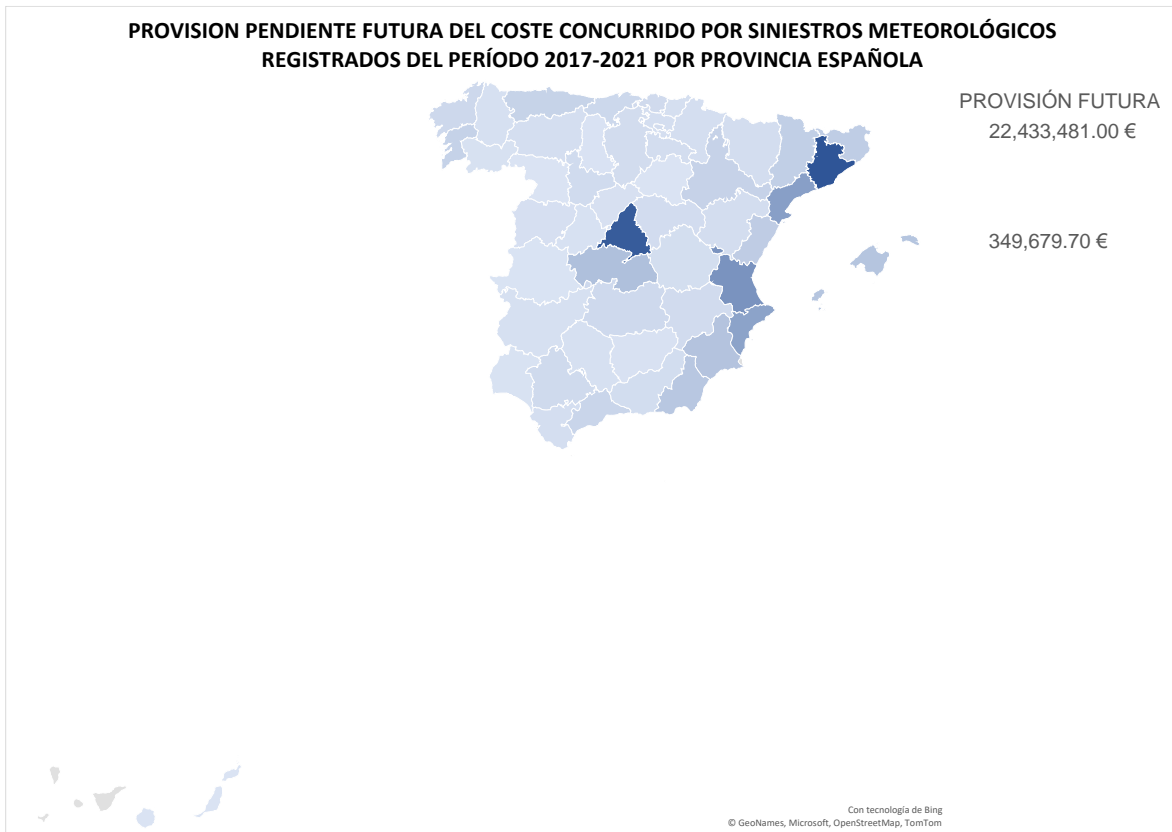
Además, ambos triángulos de desarrollo reflejan que los importes de los siniestros tienden a incrementarse en los años posteriores al año en que se reportan inicialmente. Esto sugiere que los costos finales de los siniestros pueden ser más altos de lo que se estima inicialmente, lo que implica la necesidad de contar con provisiones suficientes para cubrir estos costos futuros adicionales.

Esta tendencia sugiere que, en la evaluación del riesgo y la gestión de siniestros, tanto en Barcelona como en Burgos, las proyecciones iniciales de los costos pueden subestimar los costos finales que eventualmente se acumularán en el futuro.

Cabe resaltar que, a pesar de las similitudes en los patrones de desarrollo, los importes involucrados son significativamente diferentes entre las dos provincias, siendo los importes para Barcelona mucho mayores que para Burgos, lo cual es indicativo de una evidente mayor exposición al riesgo en Barcelona que en Burgos.



## 5. Resultados y conclusión



Ver *Tabla de provisiones pendientes para las provincias españolas* en el apartado **VII. ANEXOS**

La tabla ([Tabla de provisiones pendientes para las provincias españolas](#)) muestra la provisión de fondos futura, que representa la cantidad de dinero reservada para cubrir siniestros meteorológicos en cada provincia española, correspondiente al período 2017-2021.

En primer lugar, se puede apreciar una gran variabilidad en la provisión de fondos entre las distintas provincias. Esto puede deberse a varios factores, incluyendo la frecuencia y la gravedad de los eventos meteorológicos adversos en cada provincia, la población y la infraestructura existente, y la capacidad económica de cada provincia para soportar estos costos.

Las provincias de Barcelona (22,433,481.00 €) y Madrid (21,386,618.00 €) tienen las provisiones de fondos más altas. Esto no es sorprendente, ya que son las dos provincias más pobladas de España y también tienen una alta concentración de infraestructuras que podrían verse afectadas por eventos meteorológicos adversos.

Por otro lado, provincias como Soria (362,496.30 €), Las Palmas (349,679.70 €) y Zamora (398,178.60 €) tienen las provisiones más bajas. Esto puede deberse a que estas provincias son menos pobladas y/o tienen menos infraestructura susceptible a daños por eventos meteorológicos, o tal vez estos lugares tienen menos ocurrencias de estos eventos.

Las provincias catalanas también tienen provisiones de fondos relativamente altas, que podrían estar relacionadas con su ubicación costera y la potencial amenaza de eventos climáticos como inundaciones y tormentas marítimas.

La tabla refleja la anticipación financiera a los daños causados por fenómenos meteorológicos adversos en las diferentes provincias de España, lo que podría ser un indicativo de la vulnerabilidad de cada región a estos eventos y de la capacidad de cada una de ellas para enfrentar sus consecuencias económicas.

## V. CONCLUSIONES DESTACADAS

### 1. Síntesis de los resultados

Mediante el análisis factorial del CASO PRÁCTICO 1, el presente estudio identificó dos factores principales de riesgo en los siniestros industriales en España que tuvieron entre los años 2021 y 2022:

- El primer factor está relacionado con problemas operativos cotidianos, que pueden causar interrupciones en las actividades normales de la empresa y provocar retrasos o pérdida de producción. Las provincias que más se ven afectadas por este tipo de riesgos, según el estudio, son Sevilla y Huesca. En estos lugares, los problemas diarios de logística, equipo y operaciones son predominantes.
- El segundo factor engloba eventos más serios e impredecibles que pueden amenazar la seguridad de los empleados, el inventario y la infraestructura de la empresa, poniendo en riesgo su viabilidad a largo plazo. Este tipo de riesgos son más prevalentes en Barcelona, Valencia, Murcia, varias regiones de Andalucía y Madrid. Aquí, las empresas se enfrentan a un mayor riesgo de accidentes importantes que dependen de eventos bastante aleatorios y que están fuera del control de la empresa.

En relación con las provisiones necesarias que han sido calculadas en el CASO PRÁCTICO, se tomaron en cuenta la cantidad discreta de siniestros y los costos promedio asociados a los eventos meteorológicos entre 2017 y 2021 que han tenido lugar en la Península Ibérica e Islas para calcular la cuantía total a afrontar en base a una distribución hipotética a pagar durante los años de desarrollo.

La densidad poblacional y el riesgo de accidentes meteorológicos difieren en cada provincia, con Barcelona y Burgos como ejemplos destacados. Los costos en Barcelona fueron mucho mayores, lo que indica una exposición al riesgo climático mayor. Algunas de las provincias que cuentan con elevadas reservas financieras para daños meteorológicos entre 2017 y 2021 fueron Valencia (12.802.077,00 €) y Tarragona (10.934.139,00 €), las cuales corren un mayor riesgo de sufrir eventos meteorológicos al ubicarse en zonas costeras y contar con población significativa.

Concluyendo, los costos varían según la densidad poblacional y el riesgo meteorológico de cada provincia. Cabe destacar que podría suceder llegar a suceder que el costo final de los siniestros superase las estimaciones iniciales, como se evidenció con el alto costo de los escombros por el huracán Gloria en 2020.

## **2. Implicaciones en la gestión de riesgos contemplada en seguros multirriesgo**

El seguro multirriesgo requiere una identificación y evaluación adecuadas de los riesgos potenciales en función de una serie de factores determinantes de cada industria, tal y como medir la frecuencia y la gravedad de las condiciones meteorológicas condicionantes. Además, las aseguradoras deben implementar medidas de mitigación de riesgos y más en regiones con fenómenos catastróficos frecuentes.

El costo estimado del reclamo afecta el precio de la prima del seguro. En una provincia como Barcelona u otra región con mayores costes de reserva, pueden exigir primas más altas para compensar el riesgo adicional. Eso se debe a que las compañías de seguros deben tener reservas suficientes para cubrir los costos de reclamaciones futuras. Las proyecciones de costes de reposición futuros son imprescindibles para el cálculo de las reservas exigidas. El cálculo de provisiones debe tener en cuenta que el costo final de los siniestros puede superar las estimaciones iniciales, lo que destaca la necesidad de contar con reservas adecuadas.

El análisis en la gestión de riesgos de tener siniestros muestra la importancia de considerar tanto los problemas operativos diarios como los eventos impredecibles al gestionar los seguros multirriesgo industriales. La densidad poblacional y el grado de exposición a eventos meteorológicos también influyen en el riesgo.

## VI. REFERENCIAS BIBLIOGRÁFICAS Y WEBGRAFIA

- Boj, E.; Claramunt, M.M.; Costa, T. (2020). Tarificación y provisiones (tercera edición). Depósito Digital de la Universidad de Barcelona. Colección de objetos y materiales docentes (OMADO). <http://hdl.handle.net/2445/149241>
- Claramunt, M.M.; Costa, T.; Boj, E. (2017). *provisio*: Área de trabajo en lenguaje R para el cálculo de provisiones técnicas en seguros no de vida con métodos deterministas. Depósito Digital de la Universidad de Barcelona. Colección de Investigación - Software. <http://hdl.handle.net/2445/106653>
- Uriel, E.; Aldás, J. (2005). Análisis multivariante aplicado: aplicaciones al marketing, investigación de mercados, economía, dirección de empresas y turismo. Madrid: Thomson. ISBN: 978-84-9732-384-1.
- Alegre, A.; Badía, C.; Boj, E.; Bosch, M.; Casanovas, M.; Castañer, A.; Claramunt, M.M.; Costa, T.; Galisteo, M.; González-Vila, L.; Mármol, M.; Martínez de Albéniz, F.J.; Morillo, I.; Ortí, F.J.; Pons, M.A.; Preixens, T.; Ribas, C.; Roch, O.; Sáez, J.; Sarrasí, F.J.; Varea, J. (2017). Teoría General del Seguro . (pp. 1 - 332) . Asociación ICEA . ISBN: 978-84-697-6093-2
- Kahneman, D. (2013). Pensar rápido, pensar despacio: 320 (Ensayo | Psicología). Libro de bolsillo – 19 septiembre. Debolsillo. Traducido por Joaquín Chamorro Mielke. 6ª edición. ISBN: 978-84-9032-250-5.

<https://www.unespa.es/que-fem/publicaciones/informes-2023/>

<https://www.fundacionmapfre.org/publicaciones/>

<https://www.fundacionmapfre.org/publicaciones/diccionario-mapfre-seguros/>

<https://dgsfp.mineco.gob.es/es/Publicaciones/DocumentosPublicacionesInforme%20del%20Sector%202020.pdf>

<https://www.estamos-seguros.es/unespa/>

<https://www.miteco.gob.es/ca/calidad-y-evaluacionambiental/temas/responsabilidad-mediambiental/>

<https://www.unespa.es/notasdeprensa/siniestros-meteorologicos-2017-2021/>

[https://www.miteco.gob.es/es/cambio-climatico/temas/impactos-vulnerabilidad-y-adaptacion/15\\_sector\\_del\\_seguro\\_2\\_tcm30-178508.pdf](https://www.miteco.gob.es/es/cambio-climatico/temas/impactos-vulnerabilidad-y-adaptacion/15_sector_del_seguro_2_tcm30-178508.pdf)

<https://www.inese.es/los-fenomenos-meteorologicos-suponen-el-168-de-la-siniestralidad-de-los-multirriesgos/>

-

[https://www.cienciadedatos.net/documentos/58\\_mapas\\_con\\_r](https://www.cienciadedatos.net/documentos/58_mapas_con_r)

<https://www.modeldifferently.com/2020/10/como-dibujar-mapas-en-r/>

<https://prevencionar.com/2019/08/06/alerta-por-el-aumento-de-los-accidentes-en-el-sector-de-la-construccion/>

<https://theobjective.com/economia/2023-01-08/mortalidad-construccion/>

<https://www.observatoriodelaconstruccion.com/articulos/detalle/la-siniestralidad-en-la-construccion-requiere-mas-inversiones-y-profundizar-en-las-medidas-preventivas>

[https://www-elindependiente.com.cdn.ampproject.org/v/s/www.elindependiente.com/economia/pymes-autonomos/2020/03/20/empresas-muy-pequenas-un-grave-problema-para-la-siniestralidad/amp/?amp\\_gsa=1&amp\\_js\\_v=a9&usqp=mq331AQIUAKwASCAAqM%3D#amp\\_tf=De%3A%20%251%24s&aoh=16859208600399&csi=1&referrer=https%3A%2F%2Fwww.google.com&ampshare=https%3A%2F%2Fwww.elindependiente.com%2Feconomia%2Fpymes-autonomos%2F2020%2F03%2F20%2Fempresas-muy-pequenas-un-grave-problema-para-la-siniestralidad%2F](https://www-elindependiente.com.cdn.ampproject.org/v/s/www.elindependiente.com/economia/pymes-autonomos/2020/03/20/empresas-muy-pequenas-un-grave-problema-para-la-siniestralidad/amp/?amp_gsa=1&amp_js_v=a9&usqp=mq331AQIUAKwASCAAqM%3D#amp_tf=De%3A%20%251%24s&aoh=16859208600399&csi=1&referrer=https%3A%2F%2Fwww.google.com&ampshare=https%3A%2F%2Fwww.elindependiente.com%2Feconomia%2Fpymes-autonomos%2F2020%2F03%2F20%2Fempresas-muy-pequenas-un-grave-problema-para-la-siniestralidad%2F)

## VII. ANEXOS

### 1. Herramienta en R: Elaboración de mapas para el análisis factorial

```
install.packages(c("sf", "ggplot2", "dplyr"))
library(sf)
library(ggplot2)
library(dplyr)

setwd("~/Desktop/tfg/lineas_limite/SHP_ETRS89/recintos_provinciales_inspire_peninbal_etr89")

peninsula_baleares <- read_sf(setwd("~/Desktop/tfg/lineas_limite/SHP_ETRS89/recintos_provinciales_inspire_peninbal_etr89"), quiet= TRUE)
peninsula_baleares$NAMEUNIT

peninsula_baleares <- peninsula_baleares %>%
  filter(NAMEUNIT!= "Territorio no asociado a ninguna provincia", NAMEUNIT!= "Ceuta",
NAMEUNIT!= "Melilla")

peninsula_baleares$NAMEUNIT <- case_when(
  peninsula_baleares$NAMEUNIT == "A Coruña" ~ "La Coruña",
  peninsula_baleares$NAMEUNIT == "Alacant/Alicante" ~ "Alicante",
  peninsula_baleares$NAMEUNIT == "Araba/Álava" ~ "Álava",
  peninsula_baleares$NAMEUNIT == "Bizkaia" ~ "Vizcaya",
  peninsula_baleares$NAMEUNIT == "Castelló/Castellón" ~ "Castellón",
  peninsula_baleares$NAMEUNIT == "Gipuzkoa" ~ "Guipúzcoa",
  peninsula_baleares$NAMEUNIT == "Girona" ~ "Gerona",
  peninsula_baleares$NAMEUNIT == "Illes Balears" ~ "Islas Baleares",
  peninsula_baleares$NAMEUNIT == "Lleida" ~ "Lérida",
  peninsula_baleares$NAMEUNIT == "Ourense" ~ "Orense",
  peninsula_baleares$NAMEUNIT == "València/Valencia" ~ "Valencia",
  TRUE ~ peninsula_baleares$NAMEUNIT)
```

```

summary(peninsula_baleares$NAMEUNIT) #48 provincias

# Cargar shp file que contiene las 2 provincias de Canarias
setwd("~/Desktop/tfg/lineas_limite/SHP_REGCAN95/recintos_provinciales_inspire_canarias_re
gcan95")
islas_canarias <- read_sf(setwd("~/Desktop/tfg/lineas_limite/
SHP_REGCAN95/recintos_provinciales_inspire_canarias_regcan95"),
quiet = TRUE)
islas_canarias$NAMEUNIT

islas_canarias$NAMEUNIT <- case_when(
  islas_canarias$NAMEUNIT == "Santa Cruz de Tenerife" ~ "S. C. Tenerife", TRUE ~
islas_canarias$NAMEUNIT)

peninsula_baleares %>% ggplot() + geom_sf(fill = "lightyellow",
color = "black") + geom_sf_label(aes(label = NAMEUNIT), size = 1.5, fontface = "bold") +
theme_bw()

islas_canarias %>% ggplot() + geom_sf(fill = "lightyellow", color = "black") +
geom_sf_label(aes(label = NAMEUNIT), size = 1.5, fontface = "bold") + theme_bw()

peninsula_baleares_tol <- peninsula_baleares %>% st_simplify (dTolerance = 1e-03)

peninsula_baleares_tol %>% ggplot()+ geom_sf(fill = "lightyellow", color = "black") +
geom_sf_label(aes(label = NAMEUNIT), size = 1.5, fontface = "bold") + theme_bw()
islas_canarias_tol <- islas_canarias %>% st_simplify(dTolerance = 1e-03)
islas_canarias_tol %>% ggplot() + geom_sf(fill = "lightyellow", color = "black") +
geom_sf_label(aes(label = NAMEUNIT), size = 1.5, fontface = "bold") + theme_bw()

# Transformar sistema referencia coordenadas canario al peninsular con la función
st_transform para que tengan el mismo CRS
islas_canarias_transformado <- islas_canarias_tol %>%
st_transform(st_crs(peninsula_baleares_tol))

# Unir los dos conjuntos geométricos con la función rbind
prov_esp <- rbind(peninsula_baleares_tol, islas_canarias_transformado)

prov_esp %>% ggplot() + geom_sf(fill = "lightyellow", color =
"black") + geom_sf_text(aes(label = NAMEUNIT), size = 1.5,
fontface = "bold") + theme_bw()

# Acercar las Canarias a la península
crs <- st_crs(peninsula_baleares_tol)
canarias_geom <- islas_canarias_tol %>% st_transform(crs) %>% st_geometry()

canarias_shifted_geom <- canarias_geom + c(5, 7)
islas_canarias_transformado <- islas_canarias_tol %>%
  st_set_geometry(canarias_shifted_geom) %>% st_set_crs(crs)

prov_esp <-
rbind(peninsula_baleares_tol, islas_canarias_transformado)

prov_esp %>% ggplot() + geom_sf(fill = "lightyellow", color = "black") +
geom_sf_text(aes(label = NAMEUNIT), size = 1.5, fontface = "bold") + theme_bw()

# Quitar coordenadas
theme_custom_map <- function(base_size = 11,
                             base_family = "",
                             base_line_size = base_size / 22,
                             base_rect_size = base_size / 22) {
  theme_bw(base_size = base_size,
           base_family = base_family,
           base_line_size = base_line_size) %>% replace%
  theme(axis.title = element_blank(), axis.text = element_blank(), axis.ticks =
element_blank(), complete = TRUE)}

# Gráfico sin coordenadas

```

```

prov_esp %>% ggplot() + geom_sf(fill = "lightyellow", color = "black") +
geom_sf_text(aes(label = NAMEUNIT), size = 1.5, fontface = "bold") + theme_bw() +
theme_custom_map() + theme(panel.background = element_rect(fill = "lightblue"))
prov_esp$NAMEUNIT #Nombre provincias archivo shp
data$Provincia #Nombre provincias base datos original exportada

# Chequear que los nombres coincidan para correcta correspondencia
prov_esp_ordenado <- sort(prov_esp$NAMEUNIT) #la función sort ordena por orden alfabético
A-Z y la función all verifica si T o F
all (data$Provincia == prov_esp_ordenado) #[1] TRUE

## FACTOR1 ##
data_factor1 <- data.frame(Provincia = prov_esp_ordenado, Factor1 = fac1$scores[,1])
mapa_datos1 <- left_join(prov_esp, data_factor1, by = c("NAMEUNIT" = "Provincia"))
names(mapa_datos1)
mapa_datos1$NAMEUNIT
mapa_datos1$Factor1
mapa_datos1 <- st_as_sf(mapa_datos1)
mapa_datos1$SignFactor1 <- ifelse(mapa_datos1$Factor1 > 0, "Positive", "Negative")
all(mapa_datos1$NAMEUNIT==prov_esp$NAMEUNIT) #[1] TRUE
all(prov_esp_ordenado==data$Provincia) #[1] TRUE

# Gráfico final F1
ggplot() + geom_sf(data = mapa_datos1, aes(fill = ifelse(Factor1 < 0, "Negativo",
"Positivo")), size=2) + scale_fill_manual(values = c("Negativo" = "white", "Positivo" =
"orange"), labels = c("Signo negativo", "Signo positivo")) + geom_sf_text(data =
prov_esp, aes(label = NAMEUNIT), size = 1.5) + coord_sf() + theme_bw() +
theme_custom_map() + labs(fill = "Contribución F1") + ggtitle
("Contribuciones del primer factor por provincia") + theme
(panel.background = element_rect(fill = "lightblue"), legend.position = "right",
legend.justification = "center", plot.title = element_text(size = 10))

## FACTOR2 ##
data_factor2 <- data.frame(Provincia = prov_esp_ordenado, Factor2 = fac1$scores[,2])
mapa_datos2 <- left_join(prov_esp, data_factor2, by = c("NAMEUNIT" = "Provincia"))
names(mapa_datos2)
mapa_datos2$NAMEUNIT
mapa_datos2$Factor2
mapa_datos2 <- st_as_sf(mapa_datos2)
mapa_datos2$SignFactor2 <- ifelse(mapa_datos2$Factor2 > 0, "Positive", "Negative")
all(mapa_datos2$NAMEUNIT==prov_esp$NAMEUNIT) #[1] TRUE
all(prov_esp_ordenado==data$Provincia) #[1] TRUE

# Gráfico final F2
ggplot() + geom_sf(data = mapa_datos2, aes(fill = ifelse(Factor2 < 0, "Negativo",
"Positivo")), size=2) + scale_fill_manual(values = c("Negativo" = "white", "Positivo" =
"lightgreen"), labels = c("Signo negativo", "Signo positivo")) + geom_sf_text(data =
prov_esp, aes(label = NAMEUNIT), size = 1.5) + coord_sf() + theme_bw() + theme_custom_map()
+ labs(fill = "Contribución F2") + ggtitle("Contribuciones del segundo factor por
provincia") + theme(panel.background = element_rect(fill = "lightblue"), legend.position =
"right", legend.justification = "center", plot.title = element_text(size = 10))

```

## 2. Herramienta en R: Estimación de provisiones mediante un menú de selección para cualquier territorio geográfico provincial español de los siniestros climáticos entre los años 2017 y 2021

En esta sección, se presenta una herramienta implementada en R diseñada para calcular provisiones de siniestros climáticos en cualquier provincia española desde 2017 hasta 2021. Mediante un menú de selección, los usuarios pueden especificar opciones de cálculo para el período y la ubicación. La herramienta estima la reserva financiera necesaria para cubrir futuros siniestros climáticos, proporcionando una evaluación eficiente y sistemática de la carga financiera de tales eventos.



```

provincias <- cost_pro$PROVINCIA ; provincias
seleccionar_provincia <- funcion(provincias) {
  cat("Seleccionar una provincia de la lista:\n")
  for (i in 1:length(provincias)) {cat(paste(i, "-", provincias[i], "\n"))}
  id <- as.integer(readline(prompt="Introducir el número de la provincia (1-50): "))
  return(id)}
id <- seleccionar_provincia(provincias)
if (id >= 1 && id <= 50) {calculos_provincia <- funcion(id, Coste, hip_pag) {
  c0 <- hip_pag * Coste[id, 2]
  c1 <- hip_pag[1:4] * Coste[id, 3]
  c2 <- hip_pag[1:3] * Coste[id, 4]
  c3 <- hip_pag[1:2] * Coste[id, 5]
  c4 <- hip_pag[1] * Coste[id, 6]
  return(c(c0, c1, c2, c3, c4)) }
calculos <- calculos_provincia(id, Coste, hip_pag)
ibnr_resultado <- ibnrchl(calculos)
  cat("El resultado para ", provincias[id], "es:\n") print(ibnr_resultado)} else
{cat("Número inválido.")}

```

### 3. Tabla de provisiones pendientes para las provincias españolas

	PROVINCIAS ESPAÑOLAS	PROVISIÓN FUTURA			
1	Álava	1,097,418.00 €	26	La Rioja	1,268,837.00 €
2	Albacete	1,562,155.00 €	27	Las Palmas	349,679.70 €
3	Alicante	10,377,675.00 €	28	León	1,172,190.00 €
4	Almería	4,680,458.00 €	29	Lérida	3,526,029.00 €
5	Asturias	2,901,345.00 €	30	Lugo	858,322.20 €
6	Ávila	708,716.70 €	31	Madrid	21,386,618.00 €
7	Badajoz	840,633.80 €	32	Málaga	2,562,786.00 €
8	Barcelona	22,433,481.00 €	33	Murcia	5,274,529.00 €
9	Burgos	1,442,300.00 €	34	Navarra	1,119,397.00 €
10	Cáceres	421,014.10 €	35	Orense	713,096.10 €
11	Cádiz	1,066,456.00 €	36	Palencia	464,182.80 €
12	Cantabria	2,136,115.00 €	37	Pontevedra	3,022,836.00 €
13	Castellón	3,873,127.00 €	38	Salamanca	930,595.50 €
14	Ciudad Real	1,835,614.00 €	39	S.C.Tenerife	437,750.80 €
15	Córdoba	807,864.80 €	40	Segovia	780,608.60 €
16	Cuenca	1,200,123.00 €	41	Sevilla	1,781,412.00 €
17	Gerona	3,809,875.00 €	42	Soria	362,496.30 €
18	Granada	1,336,579.00 €	43	Tarragona	10,934,139.00 €
19	Guadalajara	1,412,758.00 €	44	Teruel	1,209,236.00 €
20	Guipúzcoa	1,042,525.00 €	45	Toledo	5,860,867.00 €
21	Huelva	581,306.20 €	46	Valencia	12,802,077.00 €
22	Huesca	1,287,960.00 €	47	Valladolid	1,665,220.00 €
23	Islas Baleares	5,089,167.00 €	48	Vizcaya	1,675,451.00 €
24	Jaén	608,527.30 €	49	Zamora	398,178.60 €
25	La Coruña	1,997,669.00 €	50	Zaragoza	2,951,308.00 €

