
**UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE CIENCIAS ECONÓMICAS
Y DE ADMINISTRACIÓN**

**TRABAJO FINAL PARA OBTENER EL
TÍTULO DE
MAESTRÍA EN GESTIÓN DE EMPRESAS DE
TECNOLOGÍAS DE LA INFORMACIÓN**

Uso de Inteligencia Artificial en el proceso de otorgamiento
de becas de posgrado en la FCEA - UDELAR

por

JOSÉ IGNACIO INFANTE PÉREZ

TUTORA: PROF. MYRIAN ERRECALDE

Montevideo
URUGUAY 2024

Página de Aprobación

El tribunal docente integrado por los abajo firmantes aprueba el Trabajo Final:

Título

.....
.....
.....
.....

Autor/es

.....
.....

Tutor/Coordinador

.....
.....

Posgrado

.....
.....

Puntaje

.....

Tribunal

Profesor.....
.....(nombre y firma).

Profesor.....
.....(nombre y firma).

Profesor.....
.....(nombre y firma).

FECHA.....

Resumen del Proyecto y palabras claves

Resumen:

La Inteligencia Artificial (IA) permite en la actualidad automatizar el proceso de toma de decisiones equitativamente y procesar grandes volúmenes de datos, por lo que una herramienta diseñada utilizando esta nueva tecnología, es un aporte novedoso y actual para las organizaciones y sus integrantes.

En la actualidad, el análisis de las solicitudes de becas de apoyo económico a los estudiantes de posgrado de las diferentes carreras de la facultad de Ciencias Económicas y de Administración (FCEA) de la Universidad de la República (UdelaR), se realiza de manera manual y está a cargo de una comisión. La decisión de otorgamiento suele demorar varios meses, dejando al estudiante en la incertidumbre de si podrá cursar o no un posgrado. Se plantea la posibilidad de diseñar un sistema automatizado utilizando estrategias de IA para el análisis de las solicitudes que disminuya el tiempo de respuesta.

La pregunta que guía este trabajo final es ¿cómo la IA puede mejorar el proceso de la entrega de becas de apoyo económico para estudiantes de posgrado de FCEA? Para responder esta pregunta se buscará identificar soluciones basadas en IA que puedan mejorar el proceso de otorgamiento. Para ello, deberán identificarse aquellos datos que se completan en el formulario y que son relevantes para tomar la decisión de otorgamiento.

Esta propuesta beneficiará a los postulantes y a la comisión de becas. Por un lado, los postulantes recibirán la respuesta en menor tiempo, para así tomar la decisión de cursar un posgrado o no. Por el otro, permitirá a la comisión de becas disminuir el tiempo de análisis de las solicitudes.

Otorgar becas de apoyo económico para las carreras de posgrados brindadas por FCEA de manera más rápida y eficiente, claramente será algo novedoso y original, porque actualmente no se dispone de nada similar y se tarda en ocasiones más de 3 meses en responder a los postulantes.

La metodología a utilizar será principalmente exploratoria y cualitativa basada en estudio de caso. Si bien se usarán datos cuantitativos, como la demora en la respuesta a las solicitudes, la principal fuente de datos en el estudio documental de las solicitudes y entrevistas en profundidad a integrantes de la comisión para identificar las variables relevantes. Además, deberán identificarse qué tipo de herramienta de IA podrá aplicarse en el proceso. Luego se utiliza un enfoque explicativo para identificar cómo se han tomado las decisiones en el proceso de otorgamiento. De esta manera, se podrán determinar los criterios que permitan automatizar el proceso utilizando IA.

Palabras claves:

Becas, inteligencia artificial, métodos de aprendizaje automáticos, automatización

Contenido

Página de Aprobación.....	ii
Resumen del Proyecto y palabras claves	iii
Abreviaturas.....	v
1. Justificación.....	1
2. Planteamiento del tema/problema	2
3. Objetivos	3
3.1. Objetivo general.....	3
3.2. Objetivos específicos	3
4. Hipótesis.....	4
4.1. Primera hipótesis.....	4
4.2. Segunda hipótesis	4
4.3. Tercera hipótesis	4
4.4. Cuarta hipótesis.....	4
5. Marco teórico	5
5.1. Inteligencia artificial aplicada a la toma de decisiones.....	5
5.2. Etiquetas.....	7
5.3. El impacto de la IA en el proceso de toma de decisiones.....	8
5.4. Algunas aplicaciones de IA en procesos de toma de decisiones	9
6. Metodología y técnicas.....	12
7. Diagnóstico de la situación actual	13
7.1. Entrevistas.....	13
7.2. Criterios para el otorgamiento de becas.....	14
7.3. Formulario	14
8. Propuesta teórica de solución.....	17
8.1. Análisis de implementación de MAA supervisado.....	18
8.2. Análisis de implementación de MAA semisupervisado	21
8.3. Propuesta de solución	23
9. Conclusiones	25
10. Referencias bibliográficas y bibliografía.....	28
11. Anexos	29
11.1. Entrevistas	29
11.1.1. Entrevista con Silvina Nápoli.....	29
11.1.2. Entrevista con la comisión de Becas	30
11.2. Formulario de solicitud de una beca de apoyo económico en FCEA	32

Abreviaturas

FCEA	Facultad de ciencias económicas y de administración
IA	Inteligencia artificial
MAA	Método de aprendizaje automático
UDELAR	Universidad de la república

1. Justificación

La maestría de Gestión de Empresas de Tecnologías de la Información señala que uno de los objetivos es formar profesionales que identifiquen, desarrollen y gestionen los beneficios que la tecnología puede brindar a las organizaciones. Por lo tanto, este trabajo final se fundamenta en la posibilidad de realizar un aporte tecnológico a los posgrados de FCEA de UdelaR, más precisamente al proceso de otorgar becas de apoyo económico para los diferentes posgrados.

La FCEA de UdelaR brinda un sistema de becas para que los alumnos de posgrado puedan cursar una Especialización o Maestría. Dado que la formación continua es una de las preocupaciones de los profesionales actuales que deseen mantenerse activos en su proceso de formación, es fundamental que esta posibilidad de acceder a una beca de estudios pueda ser respondida en un tiempo prudencial. Por este motivo, el problema planteado puede ser solucionado con un aporte que logre la automatización de este proceso.

La IA permite en la actualidad automatizar el proceso de toma de decisiones equitativamente y procesar grandes volúmenes de datos, por lo que una herramienta diseñada utilizando esta nueva tecnología, será un aporte novedoso y actual para la organización y sus integrantes. Así mismo, esta propuesta beneficiará a los postulantes principalmente, ya que obtendrán una respuesta en menor tiempo. Otorgar becas de apoyo económico para las carreras brindadas por FCEA de manera más rápida y eficiente, claramente será algo novedoso y original, porque actualmente no se dispone de ninguna herramienta que permita tomar estas decisiones de manera eficiente.

2. Planteamiento del tema/problema

La FCEA de UdelaR otorga becas de apoyo económico para que los estudiantes puedan realizar estudios de posgrado. El proceso actual por el cual se determina el otorgamiento, en la actualidad, es manual y demora hasta tres meses en definir el resultado de la postulación a la beca.

En primer lugar, la administración de posgrados recibe todas las solicitudes de los postulantes, para lo cual se establece una fecha límite. Luego las separa por posgrados y determina el orden de análisis según la fecha de inicio de los posgrados.

En segundo lugar, se envían todas las solicitudes a la comisión de becas y ellos se expiden considerando la información presentada y el porcentaje solicitado, pudiendo otorgar una beca, pero con un porcentaje diferente al solicitado. Si se solicita un porcentaje que sea superior al 65 %, esas solicitudes son analizadas por los integrantes del Consejo de FCEA, para determinar si se otorga o no.

La comisión está formada por los 3 órdenes de facultad, egresados, docentes y estudiantil. Cabe destacar que sus integrantes tienen calidad de voluntarios, por lo que no se puede exigir un límite de tiempo para que realicen el análisis y emitan las diferentes resoluciones a cada una de las solicitudes. Generalmente, el proceso de análisis es cuando finaliza el año lectivo. En este período, el orden docente debe evaluar y cerrar notas. Por correcciones de evaluaciones. El orden estudiantil también está atareado con todo lo relacionado al cierre de cursos, parciales, exámenes, diferentes entregas y el orden egresado se enfrenta al cierre del año laboral con todo lo que eso implica. Por estos motivos se dificulta que se expidan con rapidez.

Por todo lo expuesto, la pregunta a investigar y tema principal de esta tesis es ¿Cómo la IA puede mejorar el proceso de la entrega de becas de apoyo económico para estudiantes de posgrado de FCEA?

De esta pregunta principal se desprenden las siguientes preguntas accesorias:

- ¿Qué tecnologías basadas en IA se pueden aplicar al proceso de toma de decisiones?
- ¿Cuáles son los datos relevantes del formulario de postulación que permiten identificar los criterios de otorgamiento?
- ¿Qué solución basada en IA permitirá automatizar el proceso de otorgamiento de becas de posgrado?

3. Objetivos

3.1. Objetivo general

Analizar e identificar soluciones basadas en inteligencia artificial que optimicen el proceso de otorgamiento de becas para estudiantes de posgrado en la Facultad de Ciencias Económicas y de Administración (FCEA), mejorando su eficiencia, transparencia y equidad.

3.2. Objetivos específicos

- Analizar los diferentes tipos de IA que hay en la actualidad, orientado a IA aplicada al análisis de datos y toma de decisiones.
- Identificar variables pertenecientes al formulario de postulación, que puedan determinar los criterios de otorgamiento.
- Proponer una solución basada en IA que permita automatizar el proceso de otorgamiento de becas de posgrado en la FCEA

El alcance de esta tesis es el de proponer la solución en forma teórica, es decir, determinar los criterios que debería utilizar el sistema cuando se desarrolle y qué tipo de IA puede utilizarse en el desarrollo.

4. Hipótesis

4.1. Primera hipótesis

La aplicación de una solución basada en IA permite optimizar el proceso de otorgamiento de becas para estudiantes de posgrado en la Facultad de Ciencias Económicas y de Administración (FCEA), mejorando su eficiencia, transparencia y equidad.

4.2. Segunda hipótesis

Existe para esta implementación de IA, un MAA mediante el cual se desarrollará el sistema de información Planificado.

4.3. Tercera hipótesis

Existe un subconjunto de puntos pertenecientes al formulario de postulación, mediante los cuales se pueden determinar los criterios de otorgamiento de becas de apoyo económico a los estudiantes.

4.4. Cuarta hipótesis

Se puede diseñar un sistema automatizado basado en IA que permita disminuir el tiempo de respuesta a los solicitantes.

5. Marco teórico

Para introducir el marco teórico, se menciona que el objetivo principal de este trabajo final es analizar la incorporación de inteligencia artificial (IA) a un proceso organizacional de toma de decisiones. En este caso se trata de la posibilidad de automatizar el proceso de otorgamiento de becas de apoyo económico a diferentes postulantes de la FCEA.

5.1. Inteligencia artificial aplicada a la toma de decisiones

La IA se puede definir como:

La capacidad de una máquina o sistema informático para simular y realizar tareas que normalmente requerirían inteligencia humana, como el razonamiento lógico, el aprendizaje y la resolución de problemas. La inteligencia artificial se basa en el uso de algoritmos y tecnologías de aprendizaje automático para dar a las máquinas la capacidad de aplicar ciertas habilidades cognitivas y realizar tareas por sí mismas de manera autónoma o semiautónoma. (Morandín-Ahuerma, 2022, p. 1947)

A medida que la IA se desarrolla, se espera que mejore la eficiencia de algunos procesos y ayude a las personas a realizar tareas complejas con mayor rapidez y precisión (Morandín-Ahuerma, 2022). Para ello se deben tener en cuenta dos conceptos: los algoritmos y el aprendizaje automático

Un algoritmo es el conjunto de pasos o reglas que puede resolver un problema o realizar una tarea específica de manera automatizada. Se utilizan en la IA para permitir que las máquinas aprendan por sí mismas y mejoren sus habilidades con el tiempo (Bleakley, 2020).

El Aprendizaje Automático es una rama de la Inteligencia Artificial que se enfoca en la creación de algoritmos capaces de aprender a partir de datos, es decir que posibilita que las computadoras adquieran conocimiento por sí mismas, sin intervención humana (Ai Lab School, 2023). Esta capacidad permite automatizar procesos de toma de decisiones, que aplican métodos de aprendizaje automático.

En la actualidad (Ai Lab School, 2022), se utilizan diferentes tipos de métodos de aprendizaje automático (MAA). Entre los que se pueden mencionar aprendizaje supervisado, no supervisado, por refuerzos y semisupervisado. Cada uno de estos métodos utiliza algoritmos diferentes.

El **aprendizaje supervisado** es uno de los enfoques más comunes en el ámbito del aprendizaje automático. En este método, el algoritmo se entrena con un conjunto de datos etiquetados, lo que significa que cada entrada tiene una salida correspondiente previamente conocida. El objetivo del modelo es aprender una función que mapee entradas a salidas de manera precisa, basándose en los datos de entrenamiento. Una vez entrenado, el modelo puede predecir salidas para nuevas entradas no vistas (Bishop, 2006).

Las principales características de estos métodos son que se entrena con datos etiquetados, se emplea para tareas de clasificación y regresión y requiere un gran volumen de datos etiquetados para obtener buenos resultados (Goodfellow, 2016). Entre sus aplicaciones se puede mencionar el reconocimiento de imágenes y rostros.

Para modelos simples como la regresión lineal, *k-NN* (*k-Nearest Neighbors*) o incluso árboles de decisión, un conjunto de datos bastante acotado, podría ser insuficiente para tareas simples de clasificación o regresión. La regresión es una técnica que pertenece al aprendizaje supervisado, ya que requiere un conjunto de datos etiquetados para entrenar el modelo. La tarea principal de un modelo de regresión es predecir valores continuos (números reales) en función de una o más variables de entrada. Esto lo diferencia de otros métodos supervisados, como la clasificación, que predicen categorías o clases discretas. Es un modelo predictivo supervisado que se entrena utilizando un conjunto de datos donde las entradas están asociadas con salidas continuas conocidas (etiquetas). Una vez entrenado, el modelo puede realizar predicciones para datos nuevos. En modelos complejos, como redes neuronales profundas o máquinas de soporte vectorial (SVM) en espacios de alta dimensionalidad, también es necesario una buena cantidad de datos en el conjunto de entrenamiento. Estos modelos tienden a requerir grandes cantidades de datos para aprender adecuadamente y generalizar bien en datos no vistos.

Un modelo simple es un modelo de aprendizaje que utiliza una estructura matemática o computacional básica para realizar predicciones. Estos modelos suelen ser interpretables, eficientes y adecuados para tareas donde los datos tienen pocas variables o las relaciones entre estas son lineales o relativamente sencillas. En el caso de la regresión, el ejemplo más representativo de un modelo simple es la regresión lineal.

A diferencia del aprendizaje supervisado, el **aprendizaje no supervisado** trabaja con datos no etiquetados. Aquí, el objetivo del algoritmo es encontrar patrones ocultos o estructuras en los datos sin ninguna instrucción explícita sobre las salidas. Este tipo de aprendizaje es útil cuando se desea explorar datos y descubrir relaciones complejas entre variables que no son obvias a simple vista (Bishop, 2006).

Las principales características de estos métodos son que se trabaja con datos no etiquetados, se emplea principalmente para la identificación de patrones, reducción de dimensiones y agrupamiento, puede ser difícil de evaluar, ya que no se cuenta con salidas conocidas para comparar los resultados (Goodfellow, 2016). Algunas aplicaciones de este tipo de aprendizaje son la segmentación de clientes en marketing, análisis de redes sociales para detectar comunidades, compresión y pre procesamiento de datos en grandes conjuntos.

El **aprendizaje por refuerzo** es un paradigma diferente de los anteriores. En lugar de trabajar con datos etiquetados o no etiquetados, este método aprende a interactuar con un entorno. La idea central es que el método toma acciones en el entorno y recibe recompensas o castigos en función de las acciones que toma. A través de este proceso de retroalimentación, el método optimiza sus políticas de decisión para maximizar las recompensas acumuladas en el tiempo (Sutton, 2018).

Las principales características de estos métodos son que se basa en la interacción continua con el entorno, no requiere datos etiquetados, el aprendizaje proviene de las recompensas obtenidas y es adecuado para problemas secuenciales donde las acciones tomadas afectan los estados futuros (Sutton, 2018). Las aplicaciones donde se destaca el uso de estos algoritmos son algunos juegos como el ajedrez y Go, donde agentes inteligentes superan a jugadores humanos, sistemas de recomendación y estrategias de marketing dinámicas, control de robots y vehículos autónomos.

El **aprendizaje semisupervisado** es un enfoque híbrido que combina elementos de los métodos supervisados y no supervisados. Se utiliza cuando se dispone de una pequeña

cantidad de datos etiquetados junto con una gran cantidad de datos no etiquetados. Este método intenta aprovechar la información de los datos no etiquetados para mejorar el rendimiento general del modelo (Goodfellow, 2016).

Las características de este tipo de métodos son, es eficaz en situaciones donde etiquetar datos es costoso o difícil, utiliza tanto datos etiquetados como no etiquetados, reduce la dependencia en la obtención de grandes cantidades de datos etiquetados. Estos algoritmos se aplican en situaciones tales como reconocimiento de voz y texto en contextos con pocos ejemplos etiquetados, clasificación de correos electrónicos en categorías de *spam* o *not spam*.

En resumen, se puede decir que los métodos de aprendizaje automático se han diversificado y especializado para abordar una amplia gama de problemas, desde la clasificación y predicción de datos hasta la interacción dinámica con entornos cambiantes. El aprendizaje supervisado es ideal para problemas donde se cuenta con grandes cantidades de datos etiquetados, mientras que el aprendizaje no supervisado se enfoca en descubrir patrones ocultos en los datos. El aprendizaje por refuerzo, por su parte, permite a los agentes aprender a tomar decisiones óptimas en escenarios secuenciales (Sutton, 2018). Finalmente, el aprendizaje semisupervisado combina lo mejor de los mundos supervisado y no supervisado, logrando resultados valiosos en situaciones donde los datos etiquetados son limitados (Goodfellow, 2016).

5.2. Etiquetas

En el aprendizaje supervisado, las etiquetas son elementos fundamentales que representan las respuestas o salidas esperadas de un conjunto de datos de entrenamiento. Estas etiquetas son proporcionadas manualmente por un experto o por un sistema automatizado, y cada una está asociada con una instancia de datos o un conjunto de características de entrada.

Una etiqueta es un valor, generalmente categórico o numérico, que indica la clase o el valor real que debe predecir el modelo. En el proceso de entrenamiento supervisado, el objetivo del algoritmo es aprender una función que mapea de forma óptima las entradas a las salidas (etiquetas) correctas.

Existen diferentes tipos de etiquetas a ser utilizadas dentro del aprendizaje supervisado, estos tipos son de clasificación, de regresión y de detección de anomalías.

Las del primer tipo se utilizan en problemas de clasificación y corresponden a categorías o clases discretas. Por ejemplo, en un modelo que distingue entre correos electrónicos de "*spam*" y "*no spam*", a cada correo electrónico se asocia con una etiqueta, esta indica una categoría o multicategoría como puede ser *spam* o *no spam*, o binarias (como "0" o "1"). Cuando es un modelo que clasifica imágenes de animales en categorías, las etiquetas podrían ser, "gato", "perro", o "pájaro" (Géron, 2019).

El segundo tipo se utiliza en problemas de regresión y corresponden a valores numéricos continuos. Por ejemplo, en un modelo que predice el precio de una vivienda, la etiqueta sería el precio real de la casa. En este tipo de problemas, el modelo debe aprender a

predecir un valor numérico preciso en función de las características proporcionadas (Mitchell, 1997).

El tercer tipo se utiliza en la detección de fraudes o anomalías e indican si una instancia es normal o anómala. Este tipo de etiquetas es crucial para que el modelo aprenda a identificar comportamientos atípicos en los datos.

Las etiquetas son esenciales porque guían el proceso de entrenamiento del algoritmo, actuando como un conjunto de ejemplos que permiten al modelo aprender de manera iterativa. Durante el proceso de entrenamiento, el modelo ajusta sus parámetros para reducir la diferencia entre sus predicciones y las etiquetas proporcionadas. Si las etiquetas son correctas y bien definidas, el modelo puede aprender con mayor precisión y generalizar bien en datos no vistos. Por otro lado, las etiquetas incorrectas o inconsistentes pueden llevar a un aprendizaje deficiente, conocido como sobreajuste (*overfitting*) o bajo ajuste (*underfitting*), lo que compromete el rendimiento del modelo cuando se aplica a nuevos datos (Géron, 2019).

Las etiquetas pueden provenir de diversas fuentes, como la anotación manual por parte de expertos humanos, la obtención de datos históricos (en el caso de problemas donde ya se conocen los resultados), o sistemas automáticos de anotación. La calidad de las etiquetas es fundamental para el éxito del modelo.

El crecimiento de estas técnicas ha impulsado significativamente el desarrollo de la inteligencia artificial y su aplicación en la vida cotidiana, desde asistentes virtuales hasta sistemas autónomos. Es evidente que a medida que los datos continúen creciendo en cantidad y complejidad, el aprendizaje automático continuará siendo un pilar fundamental en la creación de soluciones innovadoras y eficientes en diversas industrias.

5.3. El impacto de la IA en el proceso de toma de decisiones

El proceso de toma de decisiones en el ámbito organizacional ha sido históricamente una actividad intrínsecamente humana, caracterizada por el uso de heurísticas, juicios intuitivos y limitaciones cognitivas. Sin embargo, la incorporación de tecnologías avanzadas como la IA ha transformado significativamente este proceso, especialmente en entornos donde el análisis de grandes volúmenes de datos y la velocidad en la toma de decisiones son cruciales. La IA, y en particular los algoritmos de aprendizaje automático, permiten mejorar la precisión y eficiencia de las decisiones, abordando algunas de las limitaciones inherentes a la toma de decisiones humana, como los sesgos cognitivos, la fatiga y la racionalidad limitada.

En el proceso tradicional, los individuos tienden a basarse en su capacidad limitada para procesar información, lo que a menudo conduce a errores o a la adopción de soluciones subóptimas. Según Simon (1991) esta limitación se conoce como "racionalidad limitada", que describe cómo las personas toman decisiones con información incompleta o bajo condiciones de incertidumbre. Los juicios se basan frecuentemente en heurísticas, es decir, reglas prácticas simplificadas que permiten resolver problemas complejos de forma rápida, pero que también pueden conducir a sesgos sistemáticos (Kahneman, 2003). Este enfoque, aunque efectivo en ciertos contextos, es vulnerable a errores, especialmente en escenarios con grandes volúmenes de datos y múltiples variables interrelacionadas.

El impacto de la IA en la toma de decisiones ofrece soluciones a muchas de estas limitaciones humanas al automatizar y optimizar el análisis de datos. A través de la IA, es posible realizar predicciones con mayor precisión, identificar patrones ocultos en los datos y mejorar la calidad de las decisiones. Esto se logra mediante el uso de algoritmos de aprendizaje automático y profundo, que permiten a las máquinas aprender de experiencias previas y ajustar sus decisiones sobre la marcha. Estos avances han permitido que los sistemas de toma de decisiones no solo procesen grandes volúmenes de datos de manera eficiente, sino que también mejoren continuamente a medida que reciben más datos, logrando decisiones más rápidas y precisas que las realizadas por humanos.

Un aspecto clave en el cual la IA ha mostrado un valor significativo es la capacidad para superar sesgos cognitivos que afectan las decisiones humanas. Como destacan Kleinberg, J. L. (2017), los algoritmos de IA son capaces de tomar decisiones basadas en datos objetivos y patrones previamente identificados, lo que minimiza la influencia de factores emocionales o prejuicios subjetivos. En el campo legal, por ejemplo, la IA ha sido utilizada para hacer predicciones más precisas en la toma de decisiones judiciales, superando los errores asociados a las limitaciones humanas en el análisis de información compleja.

El uso de IA en la toma de decisiones tiene beneficios y limitaciones. Entre los beneficios se incluyen una mayor precisión en la predicción de resultados, la reducción de errores humanos, y la capacidad para procesar grandes volúmenes de datos en tiempo real (Brynjolfsson et al., 2011). Los autores demostraron que las organizaciones que adoptan la toma de decisiones basada en datos y utilizan IA para el análisis predictivo logran un mejor rendimiento económico y organizacional. La IA no solo permite optimizar decisiones operativas rutinarias, sino que también es capaz de abordar problemas complejos y creativos en áreas como la investigación y el desarrollo de nuevos productos.

Las limitaciones o riesgos del uso de IA en la toma de decisiones también deben ser considerados. Uno de los principales riesgos asociados es la dependencia excesiva en las decisiones automatizadas, lo que podría llevar a una falta de supervisión y control humano. Además, la adopción de sistemas de IA requiere grandes inversiones iniciales y el desarrollo de infraestructuras adecuadas para la gestión de datos, lo que puede ser una barrera significativa para algunas organizaciones. Asimismo, cuestiones éticas relacionadas con la transparencia y la equidad de los algoritmos utilizados deben ser cuidadosamente gestionados.

La IA ha revolucionado el proceso de toma de decisiones al permitir una mayor precisión, eficiencia y capacidad de aprendizaje continuo. A medida que las organizaciones adoptan estas tecnologías, es fundamental equilibrar los beneficios de la automatización con la supervisión humana, asegurando que los sistemas de IA se utilicen de manera ética y responsable. Las investigaciones indican que la integración de la IA en la toma de decisiones tiene el potencial de mejorar significativamente el rendimiento organizacional, pero también presenta desafíos que deben ser abordados para maximizar sus beneficios.

5.4. Algunas aplicaciones de IA en procesos de toma de decisiones

Si bien no se encontró bibliografía donde se aplique IA en la selección de postulantes a obtener una beca, el proceso es similar a otros de toma de decisiones organizacionales de

selección que involucre a personas. Se analizan casos de selección de recursos humanos, análisis de riesgo crediticio y otorgamiento de subsidios por desempleo.

En el caso de la selección de personal, un artículo de Fajardo Vargas (2023) investiga el uso de IA para seleccionar candidatos a puestos de trabajo basándose en criterios como competencias, habilidades y experiencia.

Tiene como objetivo reducir la intervención manual en procesos que suelen ser complejos y costosos en tiempo, asegurando decisiones más objetivas y precisas a través del uso de aprendizaje automático y algoritmos de aprendizaje supervisado para analizar datos y mejorar la toma de decisiones. Además, menciona que el proceso tradicional implica un esfuerzo manual significativo que puede ser optimizado, al mejorar la eficiencia y reducir errores humanos. El método tradicional para seleccionar al personal se realiza analizando el currículum vitae en papel e implica el análisis minucioso de cada currículum para seleccionar a aquellos que podían ser candidatos para ocupar los puestos de trabajo que se ofertaban.

Para la evaluación de idoneidad de los candidatos al puesto el modelo basado en IA usa criterios predefinidos, y toma como principales variables los puestos vacantes, las competencias requeridas y los perfiles de los candidatos, pretendiendo medir su idoneidad. La autora señala tres áreas donde la inteligencia artificial tiene un rol protagónico:

- a) Procesos de selección y contratación más justos: permite que las áreas de contratación se centren en la parte humana, ofreciendo un servicio personalizado tanto a los clientes como postulantes al cargo.
- b) Candidatos idóneos: ayuda a superar el desajuste cultural entre la organización y el candidato.
- c) Determinar patrones y tendencias en forma clara: la inteligencia artificial puede determinar fechas de contratación laboral en relación a registros de la empresa de jubilaciones o retiros de personal, también brinda asesoría en materia de competencias y habilidades necesarias para desarrollar el talento humano existente mediante capacitaciones. (Fajardo Vargas, 2023, pág. 734)

Además, sostiene que la empresa consigue una ventaja competitiva ya que mediante la aplicación de esta técnica el candidato percibe un valor agregado que resultará atractivo. Esto redundará en que la empresa pueda reducir sus esfuerzos de búsqueda.

Un caso relacionado con optimización del tiempo en la toma de decisiones utilizando IA es el análisis de riesgo crediticio (Sackiewicz, 2022). El principal objetivo del modelo predictivo es el de clasificar a los solicitantes de acuerdo con su riesgo financiero, apoyando decisiones que minimicen el riesgo de préstamos incobrables.

El proceso tradicional de análisis de riesgo crediticio se basa en un número limitado de puntos de datos, incluidos los puntajes de las agencias de crédito y la información de la solicitud del prestatario. Un sistema de inteligencia artificial puede crear un perfil de prestatario más holístico, incorporando información alternativa, como facturas de servicios públicos y pagos de alquiler, así como datos permitidos por la normativa, como el historial crediticio del prestatario con otros prestamistas.

El autor sostiene que la adopción de inteligencia artificial (IA) en la evaluación del riesgo crediticio puede convertir volúmenes masivos de datos financieros y de comportamiento del cliente en información útil. Además, al predecir resultados puede

identificar clientes que podrían recibir límites de crédito más altos, lo que puede aumentar los ingresos y la rentabilidad, al tiempo que mantiene una experiencia del cliente de primer nivel.

El análisis de crédito es un proceso de optimización y reducción de sesgos, la IA se utiliza para optimizar el proceso, trata de minimizar el tiempo y los costos de la evaluación, además de reducir la subjetividad humana. Para este análisis, la calidad de los datos de entrada es muy relevante, ya que los modelos pueden heredar sesgos si los datos no están bien estructurados o contienen sesgos históricos. Estos sesgos afectarían a las instituciones financieras.

Este conocimiento más profundo de la salud financiera de un prestatario puede respaldar decisiones más rápidas, ya sea que el prestatario sea un solicitante nuevo o un cliente existente que solicite más crédito. También admite decisiones más precisas, especialmente para clientes de archivos pequeños con poco o ningún historial crediticio. Las predicciones de riesgo no garantizan porcentajes bajos de préstamos incobrables; el enfoque no es científico, por lo que los resultados pueden juzgarse de varias maneras.

Se analiza, además, la aplicación de la IA al otorgamiento de subsidios por desempleo (Ríos, 2024).

El artículo sobre el uso de IA para subsidios de desempleo, se basa en el proceso de toma de decisiones para reducir carga administrativa y asegurar decisiones objetivas. Se emplea IA para clasificar solicitudes, solicitudes de la tecnología de Google que evalúa la aptitud para subsidios basada en criterios de desempleo. Se toma como criterio en el subsidio, la situación económica y la situación laboral.

El artículo no detalla las variables específicas que utiliza el modelo de IA de Google para evaluar las apelaciones de subsidios de desempleo. Sin embargo, menciona que el sistema está diseñado para analizar datos de los casos de manera eficiente y rápida. Es probable que se consideren factores relacionados con las solicitudes y apelaciones, como el historial laboral, documentos y cualquier evidencia presentada, pero no se especifica.

La función de la IA en la toma de decisiones, en este caso el artículo indica que la IA utilizada está basada en *Google Vertex AI Studio*, una plataforma de aprendizaje automático que permite crear, implementar y gestionar modelos de IA. Sin embargo, no se especifica el tipo exacto de modelo aplicado. Generalmente, sistemas como estos emplean algoritmos de aprendizaje supervisado o modelos de procesamiento de lenguaje natural (NLP) para analizar documentos y tomar decisiones.

La IA propone una clasificación inicial sujeta a revisión humana y sin ningún tipo de sesgo social. En este caso al igual que en los anteriores, se evidencia la necesidad de transparencia en los criterios de IA y en los mecanismos de control humano, para evitar errores que puedan afectar la equidad en decisiones sociales.

El denominador común en estas aplicaciones relacionadas en el proceso de toma de decisiones, el punto en común que tienen entre ellas y por el cual se citan, es que en todas se parte de un conjunto de datos conocidos y mediante técnicas de aprendizaje automático, se logra el entrenamiento de ciertos algoritmos, que sustituyen un trabajo manual de un grupo de humanos que realizan el análisis de cada uno de ellos, para pasar a ser realizado en forma automáticamente mediante la ejecución de un programa que de la respuesta a cada caso.

6. Metodología y técnicas

La metodología a utilizar será principalmente exploratoria y cualitativa basada en estudio de caso. Un estudio de caso puede definirse como “una investigación empírica que estudia un fenómeno contemporáneo dentro de su contexto de la vida real, especialmente cuando los límites entre el fenómeno y su contexto no son claramente evidentes” (Yin, 1994, pág. 13). El autor señala que este tipo de estudio permite analizar una situación técnicamente distintiva en la cual hay muchas más variables de interés que datos observacionales, y que se basa en múltiples fuentes de evidencia, con datos que deben converger en un estilo de triangulación.

En el presente trabajo de investigación la unidad de análisis es un proceso que se da dentro de una organización particular, el otorgamiento de becas de posgrado a estudiantes de la FCE de la UdelaR.

Los estudios exploratorios se caracterizan por estudiar un fenómeno dentro de su contexto real, que tiene situaciones únicas o poco estudiadas. Si bien se usarán datos cuantitativos, como la demora en la respuesta a las solicitudes, la principal fuente de datos en el estudio documental de las solicitudes y entrevistas en profundidad a integrantes de la comisión para identificar las variables relevantes. Además, deberá identificarse qué tipo de herramienta de IA podrá aplicarse en el proceso.

El proceso de análisis y los criterios son determinados por la comisión de becas y pueden variar año a año o con la conformación de distintas comisiones, por lo tanto, es necesario identificar cómo ha sido aplicado el criterio decisonal con anterioridad, para establecer pautas que permitan el análisis automatizado. Se utilizarán entrevistas en profundidad y análisis documental para obtener estos datos.

En una segunda etapa se utiliza un diseño explicativo, porque se busca determinar el conjunto de variables a partir de las cuales se toman las decisiones. De esta manera, se podrán determinar los criterios que permitan automatizar el proceso utilizando IA.

7. Diagnóstico de la situación actual

La FCEA de la UDELAR cuenta con dos tipos de becas que pueden solicitar los alumnos, las automáticas y las gestionables.

Las becas automáticas, como su nombre lo indica, no son sometidas a análisis por la comisión de becas. Los criterios son situaciones particulares que el estudiante debe acreditar al momento de la inscripción, tales como, cursar un posgrado dentro de los primeros 3 años de haber obtenido su título de grado. Este plazo se amplía a 6 años, si el postulante es docente de la facultad. También pueden acceder por ser funcionarios de UdelAR, o si han cursado otra carrera de posgrado anteriormente.

Este tipo de becas automáticas tiene diferentes porcentajes de descuentos, estos van desde el 10% hasta el 50% del total del posgrado seleccionado. Estos tipos de becas automáticas no son acumulables entre sí, es decir que no se suman los posibles descuentos a obtener. Por ejemplo, si el postulante tiene menos de 3 años de recibido del grado, además es docente de facultad y funcionario de la UdelAR, por lo que le corresponderían 3 tipos de becas automáticas diferentes, al momento de solicitarla, tiene que seleccionar solamente una de estas tres.

Las becas gestionables son un descuento extra que solicita el estudiante para lo cual debe completar una solicitud. El interesado debe presentar un formulario en forma completa, que tiene el efecto de declaración jurada. Estos formularios son presentados en la administración de posgrados, para que luego del cierre del periodo de postulación pasen a la comisión de becas para su estudio. Esta solicitud puede ser aprobada sin modificaciones, denegada o se puede proponer un porcentaje inferior al solicitado por el estudiante en el formulario.

Se tiene como una regla general definida por el consejo de facultad, junto con la coordinación académica de los distintos posgrados que son ofrecidos por FCEA, que el límite máximo de becas a ser entregada a un postulante no puede superar el 65% del monto total del posgrado al cual se postula. Este máximo se obtiene luego de sumar el porcentaje de becas automáticas al porcentaje de la beca gestionable.

Estos datos provienen del formulario de solicitud de cada beca. Si se considera que A es el dato al correspondiente al porcentaje de beca automática y como dato B, al correspondiente como porcentaje adicional solicitado, el porcentaje total $A + B$, no puede superar el 65 % del costo total del posgrado seleccionado. Si fuese mayor, debe elevarse al consejo de la facultad.

7.1. Entrevistas

Para profundizar en el conocimiento del proceso se entrevistó, en primer lugar, a la coordinadora académica de posgrado. Además, dado que la Comisión de becas es quien toma las decisiones actualmente, se realizaron entrevistas con algunos de sus miembros.

Para las distintas entrevistas que se realizaron, primero se trabajó en el armado de un guion, con los aspectos considerados claves que se debían considerar, permitiendo también la inclusión de preguntas abiertas que fueran surgiendo de los temas tratados.

Tanto las preguntas realizadas como sus respuestas se encuentran detalladas en el apartado de Anexos.

En primera instancia, se entrevistó a la coordinadora académica de los posgrados de FCEA, Silvina Nápoli. Esta persona es la encargada de enviar a la comisión de becas los formularios de las distintas solicitudes de becas gestionable. En segunda instancia, se realizaron entrevistas a dos miembros de la comisión de becas: el representante de los egresados, el contador Enrique Barla, y la representante del área docente, Ines Vazquez Boasso.

Los datos obtenidos permiten esclarecer los criterios que se tienen en cuenta en el proceso para el otorgamiento de becas.

7.2. Criterios para el otorgamiento de becas

El análisis esencial que se realiza para tomar la decisión es de tipo económico. Teniendo en cuenta los ingresos y gastos declarados en la solicitud, se analiza la posibilidad de que el postulante pueda pagar al menos el 35% del valor total del posgrado, que sería la beca máxima a otorgar en esta instancia, el 65 %.

A los gastos mensuales declarados por el postulante se le suma el valor del posgrado y se lo compara con los ingresos. Una vez que queda comprobada esta posibilidad se analiza en mayor detalle el porcentaje solicitado, dado que el mínimo monto a pagar está asegurado.

Este proceso es el que se realiza con todas las solicitudes. Además, se consideran otros puntos del formulario, pero este dato es en el cual la comisión de becas hizo mayor énfasis.

Si la solicitud supera el 65% del costo total del posgrado, la comisión de becas eleva esta solicitud al consejo de facultad, para que la analice y decida sobre su otorgamiento.

7.3. Formulario

El formulario de solicitud requiere que el postulante detalle la Maestría o posgrado para el que se postula y el porcentaje de beca solicitado. Además, debe añadir otros datos a los que se consideran de declaración jurada: los ingresos propios y del núcleo familiar con quien vive, así como el patrimonio de bienes inmuebles y vehículos. También se solicita un detalle de gastos mensuales por rubro.

Si se tienen en cuenta las solicitudes de becas de los últimos 4 períodos lectivos se cuenta con 58 formularios en 2024, 42 en 2023, 55 en 2022 y 63 en 2021. Considerando cada formulario como un dato del juego de datos que se tendría disponible, se podría disponer de 218 datos.

Las etiquetas a considerar para entrenamiento del modelo corresponden a las variables de entrada de cada formulario. Es decir que por cada solicitud hay varias etiquetas que determinan los criterios de aprobación. De las entrevistas realizadas, se consideran como decisionales **el porcentaje total** que solicita el postulante para cursar el posgrado elegido, **ingresos líquidos totales** del postulante, **ingresos líquidos totales del núcleo**

familiar, egresos totales del postulante, y los egresos totales del núcleo familiar. Otros datos de entrada que surgen del formulario de solicitud son los datos personales, composición del núcleo familiar y socioambientales.

El dato de salida esencial que permitirá el entrenamiento del modelo es la decisión tomada en relación de cada solicitud, si se aprobó o no y cuál fue el porcentaje otorgado. Otro dato externo necesario para tomar la decisión es el costo del posgrado para el cual se está realizando la solicitud de beca.

Para esclarecer lo antes mencionado se presenta la siguiente tabla de categorías de algunas de las etiquetas necesarias. Se referencia como interna internas si se encuentra en el formulario de solicitud y externas a las que se necesitan obtener a través de las autoridades de posgrado.

Categorías	
Internas al formulario	
ETIQUETA	DESCRIPCIÓN
IP	Disponibilidad total del postulante
IF	Ingresos de núcleo familiar
I = IP + IF	Ingresos disponibles
E	Egresos totales
D = I - E	Disponibilidad total del postulante
A	Beca automática que le corresponde al postulante
B	Beca adicional solicitada
T = A + B	Total de la beca solicitada
Externas al formulario	
TO	Total otorgado por la comisión
C	Costo del posgrado

En las etiquetas que se obtienen de los formularios de solicitud se menciona el IP (ingresos del postulante) como la sumatoria de ingreso líquido en empresa + líquido en actividad profesional + otros ingresos.

En cuanto al IF es la suma de todos los ingresos del núcleo familiar que tiene el postulante, IF = Cónyuge o integrante unión libre + Padre + Madre + Hermanos (o quien corresponda) + Rentas + Otros ingresos.

Para los E que corresponde a los egresos totales del postulante más los del núcleo familiar, para esto se debe realizar la siguiente suma de egresos, E = Alquiler o cuota vivienda + Educación hijos/cónyuges/postulante + Gastos comunes + UTE + OSE + ANTEL + GAS + CELULAR + Contribución Inmobiliaria (mensual) + Patente y seguro auto (mensual) + Cuotas Club/Gimnasio + Vestimenta + Alimentación + Otras.

La etiqueta de disponible D representa el dinero que le quedaría al postulante para efectuar el pago del posgrado seleccionado, ya que esta variable corresponde a la resta del total de los ingresos menos el total de los egresos, $D = I - E$.

Las etiquetas externas al formulario se relacionan con los resultados que del porcentaje de beca otorgado por la comisión de becas (TO). Este dato puede coincidir con el porcentaje solicitado o ser un porcentaje diferente, propuesto por la comisión.

En cuanto al costo total del posgrado (C) para el cual se hace la solicitud, es un dato que se debe obtener de las autoridades de posgrado para identificar cómo se calculó el beneficio solicitado.

8. Propuesta teórica de solución

En primer lugar, se analizan las ventajas de utilizar IA para buscar una solución al problema planteado. Esta tecnología se ha convertido actualmente en una herramienta muy poderosa para tomar decisiones en forma equitativa, analizar grandes volúmenes de datos, realizar predicciones precisas y evitar sesgos.

En primer lugar, la IA ofrece una metodología basada en datos y algoritmos para garantizar la toma de decisiones en forma equitativa, es decir que sean imparciales y consistentes. En el caso de la asignación de becas, la IA, evita la influencia de factores subjetivos. A diferencia de los juicios humanos, que pueden estar sujetos a sesgos cognitivos, emocionales o de contexto, la IA aplica los mismos criterios a todas las solicitudes. Estandariza los criterios de evaluación, al programar un sistema basado en variables objetivas (ingresos, egresos, porcentaje solicitado), se asegura una evaluación uniforme para todos los postulantes. Incrementa la transparencia, las decisiones automatizadas pueden justificarse mediante los datos y reglas empleadas, lo que aumenta la confianza de los postulantes en el proceso.

Aunque el conjunto actual de datos, obtenidos a través de 218 solicitudes, no es masivo, la IA está diseñada para escalar su capacidad de análisis. Este procesamiento resulta eficiente, incluso con un volumen relativamente moderado de datos dado que la IA puede identificar patrones y tendencias más rápidamente que un análisis manual, lo que resulta crucial para reducir los tiempos de respuesta. En cuanto a su capacidad de expansión, en el futuro, al incorporar datos históricos adicionales o nuevos periodos de solicitudes, la IA puede analizar mayores volúmenes sin perder precisión. Además, esta tecnología permite el descubrimiento de relaciones no evidentes, ya que puede detectar correlaciones entre variables como ingresos, egresos y otros factores que podrían ser ignorados en análisis manuales.

En este contexto, las predicciones precisas se refieren a decisiones de aprobación o rechazo de una solicitud. La IA puede predecir, con base en patrones históricos, si un postulante tiene altas probabilidades de cumplir los criterios para recibir una beca. Además, permite realizar el cálculo de porcentajes otorgables. Al analizar los datos del formulario, el sistema puede recomendar un porcentaje de beca más adecuado, optimizando el uso de los recursos disponibles. A largo plazo, los modelos predictivos pueden simular cómo ciertos cambios en los criterios de asignación afectarán a los futuros postulantes, ayudando en la toma de decisiones estratégicas.

La IA es una herramienta poderosa para minimizar errores derivados de la intervención humana, eliminación de inconsistencias y evitar sesgos. En el proceso manual actual, las decisiones pueden variar ligeramente debido a la interpretación de los criterios o la carga emocional de los miembros de la comisión, la IA elimina esta variabilidad. Además, factores como el cansancio, las presiones laborales o prejuicios inconscientes pueden influir en las decisiones humanas. La IA, al basarse únicamente en datos objetivos, reduce significativamente el riesgo de discriminación o favoritismo. Dado que los procesos son repetibles y auditables, cada decisión del sistema puede ser trazada y revisada, permitiendo identificar y corregir posibles errores en los algoritmos antes de que se conviertan en problemas sistémicos.

La implementación de IA en procesos de toma de decisiones, permite reducir significativamente los sesgos cognitivos y mejorar la objetividad de las evaluaciones. Según Kleinberg, (2017), los algoritmos de IA toman decisiones basadas en datos objetivos y patrones previamente identificados, minimizando la influencia de factores emocionales o prejuicios subjetivos.

Se puede concluir que la implementación de IA en el proceso de otorgamiento de becas no solo mejora la eficiencia operativa, sino que también asegura una evaluación más justa y objetiva. Los beneficios incluyen equidad en la toma de decisiones mediante la estandarización de criterios, eficiencia en el análisis y capacidad para adaptarse a volúmenes crecientes de datos. Además, permite obtener predicciones precisas y útiles para tomar decisiones informadas sobre porcentajes y recursos asignados y reducir errores y sesgos, fortaleciendo la confianza en el proceso.

Una vez determinada las ventajas de usar IA en el proceso de otorgamiento de becas, se analiza qué tipo de modelo de aprendizaje automático puede utilizarse para este proceso. A partir del conjunto de datos actuales provenientes de los años anteriores, se analizan cuáles de los métodos supervisados sería conveniente implementar para el desarrollo de la solución.

8.1. Análisis de implementación de MAA supervisado

Se comienza planteado la idea de analizar un algoritmo que utilice los datos históricos que se tienen de diferentes entregas anteriores de becas, para poder sacar un buen provecho de esto, se plantea en primera instancia la utilización de un MAA supervisado, para que aprenda patrones por los cuales sí se entregan las diferentes becas. En lugar de una programación explícita, se crean algoritmos para analizar datos y tomar decisiones de manera autónoma. (IBM, s.f.)

El aprendizaje supervisado, como rama del aprendizaje automático, es fundamental para abordar problemas que requieren decisiones basadas en datos etiquetados. En el caso del proceso de asignación de becas en la FCEA, este enfoque permite automatizar la evaluación de solicitudes al utilizar datos históricos etiquetados como referencia para predecir resultados futuros de manera precisa y equitativa.

El aprendizaje supervisado se caracteriza por la necesidad de un conjunto de datos donde las entradas, variables como ingresos, egresos y porcentaje solicitado, están asociadas a salidas conocidas, decisión de otorgar o no la beca y porcentaje otorgado. En el contexto de FCEA, este enfoque es aplicable porque se dispone de datos históricos sobre solicitudes previas y sus resultados, que pueden ser utilizados para entrenar modelos que imiten los criterios de evaluación aplicados por la comisión de becas.

En otros contextos, el aprendizaje supervisado ha demostrado ser altamente efectivo en procesos similares, proporcionando un marco robusto para la toma de decisiones basadas en patrones identificados previamente, Selección de Personal, en el ámbito de recursos humanos, algoritmos supervisados son utilizados para predecir la idoneidad de un candidato con base en datos históricos sobre contrataciones previas Fajardo Vargas, (2023). Estos sistemas identifican patrones entre variables clave como experiencia, habilidades y competencias, ofreciendo recomendaciones consistentes y objetivas. En

FCEA, un enfoque similar podría aplicarse al analizar los ingresos y egresos declarados, así como el porcentaje solicitado, para predecir si una solicitud cumple con los criterios establecidos.

En el análisis de riesgo crediticio, los modelos supervisados, se utilizan ampliamente para predecir la probabilidad de incumplimiento de pagos en solicitudes de crédito Sackiewicz, (2022). Estos modelos, entrenados con datos históricos de solicitantes, evalúan variables como ingresos, historial financiero y deuda previa para clasificar a los solicitantes según su riesgo. De manera análoga, en el proceso de asignación de becas, estos algoritmos pueden evaluar si un postulante tiene la capacidad económica suficiente para cubrir el porcentaje no subvencionado del costo del posgrado.

En el caso de otorgamiento de Subsidios por Desempleo, los algoritmos supervisados clasifican a los solicitantes con base en criterios socioeconómicos predefinidos, asegurando que las decisiones sean consistentes y libres de sesgos (Ríos, 2024). Este enfoque es relevante para el caso de FCEA, donde un modelo supervisado podría basarse en las reglas actuales, donde se considere la capacidad de cubrir al menos el 35% del costo y generar predicciones confiables sobre la asignación de becas.

El aprendizaje supervisado es muy utilizado en la inteligencia artificial y el aprendizaje automático. En este caso, los paquetes de datos usados en el aprendizaje automático supervisado se utilizan para entrenar a los algoritmos y generar información que ayude a tomar decisiones. Los algoritmos utilizan en su entrenamiento una entrada con datos etiquetados para encontrar una función y que esta asigne una salida en consecuencia de las variables de entrada, indicando al algoritmo el objetivo, es decir, qué es lo que se busca. Esto significa que cada dato de entrada tiene una única salida conocida y determinada, por lo que se facilita y posibilita dicho entrenamiento del algoritmo.

Estos métodos tienden a ser mejores y más precisos que los de aprendizaje no supervisado, esto es por disponer de datos etiquetados y tener una entrada y una salida real para esa entrada, los cuales facilitan a la toma de decisiones en nuevos y futuros casos sin etiquetar. Este tipo de aprendizaje se aplica a una amplia variedad de campos.

Por lo analizado, se evidencia que las etiquetas son fundamentales en el aprendizaje supervisado, ya que permiten al algoritmo aprender la relación entre las entradas y las salidas. La precisión y calidad del etiquetado impactan directamente en el desempeño del modelo. Un etiquetado adecuado permite al modelo generalizar mejor en nuevos datos, mientras que un etiquetado erróneo puede llevar a resultados incorrectos.

Un problema a considerar para implementar la solución es el conjunto de datos de con los que se haría el entrenamiento del algoritmo supervisado. Como se detalló se cuenta con un juego de datos de 218 solicitudes. En primer lugar, se debería realizar el etiquetado de forma manual para obtener un juego de datos de pequeña dimensión, con los que no se lograría un buen resultado.

Con 218 datos etiquetados, se debe considerar una situación limitada para la mayoría de los modelos de aprendizaje supervisado, especialmente para problemas complejos. Se analizan, a continuación, algunos problemas que pueden afectar a distintas implementaciones de los algoritmos de aprendizaje supervisados.

Si el número de características o variables en los datos es elevado (alta dimensionalidad), se requiere más información para cada característica. Con 218 datos, un alto número de variables puede hacer que el modelo no sea capaz de captar correctamente las relaciones subyacentes entre las características y las etiquetas, lo que se conoce como la maldición de la dimensionalidad.

La expresión "maldición" en el contexto de aprendizaje supervisado hace referencia a las limitaciones intrínsecas y los problemas significativos que enfrentan los algoritmos cuando trabajan con un conjunto de datos reducido, como en el caso de tener únicamente 218 datos. Este término se utiliza porque la falta de datos puede tener un impacto profundamente negativo en el desempeño del modelo, dificultando su capacidad para aprender patrones representativos y generalizar correctamente a nuevos ejemplos.

En el caso de un conjunto de datos con 218 ejemplos, la maldición puede manifestarse como una insuficiencia para modelar la complejidad del problema, ya que los algoritmos de aprendizaje supervisado necesitan una cantidad suficiente de datos para identificar patrones robustos en las relaciones entre las características y las etiquetas. Con esta cantidad de datos, es probable que la diversidad y representatividad de las muestras sean limitadas, lo que afecta directamente la capacidad del modelo para capturar la complejidad del dominio del problema.

También se debe tener en cuenta la relación entre datos y dimensionalidad, pues si los datos tienen muchas características (dimensiones), un conjunto pequeño de ejemplos no es suficiente para cubrir el espacio de características de manera adecuada. Esto provoca que el modelo no tenga suficiente información para identificar patrones generalizables, y puede ser especialmente problemático en dominios de alta dimensionalidad.

En relación al impacto estadístico, desde una perspectiva estadística, un tamaño de muestra reducido aumenta la probabilidad de variabilidad aleatoria, lo que significa que cualquier patrón observado puede no ser representativo de la población general. Esto también genera una mayor susceptibilidad a sesgos y errores debido a la falta de datos de referencia suficientes.

En síntesis, se habla de "maldición" porque el modelo enfrenta una situación adversa dado que la cantidad limitada de datos no le permite desempeñarse de manera adecuada, comprometiendo su precisión, robustez y capacidad de generalización.

Para tareas sencillas como la clasificación binaria en problemas donde las clases están claramente separadas, un conjunto de 218 datos podría ser suficiente, aunque sigue siendo un umbral bajo para garantizar una buena generalización. En tareas más complejas, como la clasificación multiclase, procesamiento de imágenes o procesamiento del lenguaje natural, 218 datos siguen siendo pocos. Estas tareas requieren una cantidad mayor de muestras para que el modelo aprenda correctamente las variaciones inherentes en los datos.

Si los datos tienen mucho ruido o una gran variabilidad entre las clases o las etiquetas, se necesitarán más datos para que el modelo pueda discernir correctamente los patrones relevantes y generalizar a nuevos ejemplos. Con 218 datos, si los datos son ruidosos, el modelo podría aprender patrones incorrectos o poco representativos.

En el aprendizaje supervisado, es común dividir el conjunto de datos en entrenamiento, validación, y prueba. Con 218 datos, una división estándar resultaría en un número pequeño de ejemplos para cada partición, lo que puede llevar a una evaluación poco confiable del rendimiento del modelo. Alternativamente, se puede usar técnicas como la validación cruzada (*cross-validation*), que permite maximizar el uso de los datos disponibles, pero aun así, un conjunto de datos pequeño sigue siendo una limitación importante.

En resumen, contar con sólo 218 datos etiquetados, en la mayoría de los casos sigue siendo insuficiente para entrenar modelos supervisados complejos. La cantidad de datos adecuada depende del tipo de tarea, la complejidad del modelo y la dimensionalidad de los datos. Para obtener resultados más robustos y evitar problemas de sobreajuste, sería recomendable contar con más datos.

8.2. Análisis de implementación de MAA semisupervisado

En este punto se analiza la aplicación de un algoritmo semisupervisado, que sería un paso intermedio a ambos tipos de algoritmos, los supervisados y los no supervisados. Se estudiará lo que sucede con este tipo de algoritmos, porque se tiene interés de sacar el mejor provecho posible al histórico de datos acumulado, a pesar de contar con una pequeña cantidad de datos.

En el caso de realizar un etiquetado de datos, se lograría obtener un conjunto limitado de datos etiquetados, como es el caso de las solicitudes de años anteriores, podría ser más conveniente utilizar aprendizaje semisupervisado. A continuación, se verán las razones para preferir el aprendizaje semisupervisado y se contrastan con el aprendizaje supervisado en esta situación.

Con una cantidad pequeña de datos, como los mencionados anteriormente, se captura ruido o características específicas de los ejemplos vistos, lo que resulta en una baja capacidad de generalización. La subrepresentación de patrones ocurre cuando el conjunto de datos carece de suficiente diversidad para abarcar todos los patrones relevantes del problema, lo que restringe la capacidad del modelo para aprender de manera efectiva y generalizar adecuadamente.

Además, en la actualidad no se dispone de datos etiquetados, es decir que se debería realizar manualmente el etiquetado de las solicitudes con las que se cuenta en la actualidad. Esto requiere que se necesite un usuario entendido en el tema al momento de entrenar dicho algoritmo, lo que aumenta el costo y el tiempo de aplicación.

Para superar este inconveniente se propone una solución que no requiera etiquetar la totalidad del conjunto de datos, permitiendo trabajar bajo las condiciones del aprendizaje semisupervisado. En este enfoque, se proporciona al algoritmo una combinación de datos etiquetados y no etiquetados, lo que facilita una exploración más amplia de las posibilidades mediante la calibración adecuada del modelo.

Para el conjunto de entrenamiento, se podría etiquetar aproximadamente el 50 % de los datos, lo que equivale a 100 ejemplos. Los 118 datos restantes permanecerán sin etiquetar, permitiendo al algoritmo explorar y aprender patrones adicionales a partir de esta

información no etiquetada, complementando así el ajuste inicial basado en los datos etiquetados.

En contraste con el aprendizaje supervisado, el aprendizaje semisupervisado puede aprovechar tanto los datos etiquetados como una gran cantidad de datos no etiquetados para mejorar el aprendizaje del modelo. Si se dispone de más datos no etiquetados, que suelen ser más fáciles de obtener que los etiquetados, aunque en este caso se dispone de los datos sin etiquetar de ediciones anterior de las entregas de becas, el modelo puede aprender relaciones estructurales en los datos no etiquetados y ajustar mejor las predicciones para los datos etiquetados. De esta manera, se mejora el rendimiento general del modelo.

En síntesis, el aprendizaje supervisado sólo utiliza los datos etiquetados, lo que limita el poder de aprendizaje cuando la cantidad de datos es pequeña, como sería el caso de los 218 datos etiquetados. En relación con este inconveniente, el aprendizaje semisupervisado utiliza tanto datos etiquetados como no etiquetados. Los datos no etiquetados permiten que el modelo explore la estructura subyacente de los datos y generalice mejor, incluso cuando la cantidad de datos etiquetados es limitada. Esto es especialmente útil cuando obtener datos etiquetados es costoso o difícil, mientras que los datos no etiquetados suelen estar más disponibles.

Por lo tanto, un algoritmo semisupervisado como *self-training* o *co-training* puede entrenarse inicialmente con los 100 datos etiquetados y luego utilizar los datos no etiquetados para seguir mejorando el modelo, permitiendo que el modelo obtenga información adicional sin necesidad de más etiquetas.

Los modelos supervisados pueden tener dificultades para generalizar cuando hay pocos datos etiquetados, mientras que un modelo semisupervisado es capaz de mejorar la capacidad de generalización porque aprenden no sólo a partir de las etiquetas, sino también de la distribución subyacente de los datos no etiquetados. Este modelo evita el sobreajuste en datos etiquetados limitados mediante el uso de los datos no etiquetados para regular el aprendizaje, lo que resulta en un mejor rendimiento en datos no vistos.

Etiquetar grandes cantidades de datos puede ser costoso y llevar mucho tiempo. El aprendizaje supervisado requiere que todos los datos sean etiquetados, lo que podría no ser práctico en muchas situaciones. En cambio, el aprendizaje semisupervisado aprovecha los datos no etiquetados, que pueden ser obtenidos de forma más económica o con menos esfuerzo, lo que lo hace más escalable en situaciones donde se dispone de pocos datos etiquetados pero muchos datos sin etiquetar.

En este caso particular, donde se dispondría de 100 datos etiquetados, el aprendizaje semisupervisado es una alternativa más adecuada que el aprendizaje supervisado, ya que permite aprovechar la estructura de datos no etiquetados para mejorar la capacidad del modelo de aprender patrones útiles y generalizar a nuevos datos. Esto mitiga la limitación del pequeño conjunto de datos etiquetados y evita problemas de sobreajuste que son comunes en el aprendizaje supervisado con conjuntos de datos pequeños.

Cabe destacar que, para iniciar el entrenamiento del algoritmo, es necesario realizar un etiquetado manual de un conjunto de datos acotados, que se realizaría por algún especializado en el tema, o por parte de los desarrolladores del algoritmo. Para ello, se

analizaría cada dato, se colocaría la etiqueta para que sea reconocida y utilizada por el algoritmo en desarrollo.

8.3. Propuesta de solución

El aprendizaje automático semisupervisado se presenta como una solución ideal para automatizar el proceso de asignación de becas en la FCEA de la Udelar. Este enfoque aprovecha tanto un subconjunto de datos etiquetados como un volumen mayor de datos sin etiquetar, permitiendo desarrollar modelos predictivos robustos y eficientes incluso en contextos donde la obtención de datos etiquetados es limitada.

En este caso particular, se dispone de un conjunto de 218 solicitudes históricas de becas, de las cuales solo 100 serían etiquetadas de forma manual para identificar patrones clave en las decisiones previas. Los restantes 118 datos no etiquetados serían integrados en el proceso de entrenamiento del algoritmo, permitiendo que este explore la estructura y optimice su capacidad predictiva. Este enfoque semisupervisado ofrece múltiples ventajas frente al aprendizaje supervisado convencional, una de las principales ventajas del enfoque semisupervisado es su eficiencia en el uso de recursos. Etiquetar manualmente todo el conjunto de datos puede ser un proceso altamente costoso y demandante en términos de tiempo y esfuerzo. Al optar por etiquetar solo una porción representativa del conjunto, se logra reducir considerablemente el trabajo requerido, sin comprometer la capacidad del modelo para aprender patrones relevantes ni su desempeño predictivo.

En primer lugar, se analiza el aprovechamiento de datos no etiquetados. Los 118 datos no etiquetados permiten al modelo aprender patrones inherentes en la distribución de los datos, ampliando su capacidad de generalización. Este método asegura que el modelo no dependa exclusivamente de un pequeño conjunto etiquetado, lo que podría limitar su desempeño.

En relación con la reducción de problemas de sobreajuste, con un conjunto reducido de datos etiquetados, un modelo supervisado podría ajustarse excesivamente a los datos disponibles, perdiendo eficacia en nuevos escenarios. En cambio, el aprendizaje semisupervisado utiliza datos no etiquetados para regular el proceso de aprendizaje, minimizando este riesgo.

Además, su aplicación práctica en contextos de recursos limitados, al requerir menos etiquetas, este enfoque es más escalable y aplicable en situaciones donde el etiquetado manual completo no es viable.

En el contexto de las solicitudes de becas, donde variables como los ingresos, gastos y porcentajes solicitados juegan un papel crucial, el aprendizaje semisupervisado permite obtener un modelo que prediga con mayor precisión las decisiones de asignación. Esto se traduce en una reducción significativa en los tiempos de respuesta, mayor equidad y un menor margen de error en la evaluación de las solicitudes.

Por último, este enfoque también aborda los desafíos asociados a la subjetividad y variabilidad humana en la toma de decisiones. Al basarse en patrones objetivos derivados de los datos históricos, el algoritmo garantiza que las decisiones sean consistentes y se ajusten a los criterios establecidos por la institución.

En conclusión, el aprendizaje semisupervisado es una herramienta estratégica que optimiza el balance entre precisión, eficiencia y equidad en la asignación de becas, permitiendo a la FCEA aprovechar al máximo su histórico de datos y responder eficazmente a las necesidades de los postulantes.

9. Conclusiones

La integración de la inteligencia artificial (IA) en la gestión de solicitudes de becas se presenta como una estrategia clave para mejorar la eficiencia operativa dentro de las instituciones educativas. En un entorno donde las solicitudes de becas pueden ser numerosas y variadas, la IA permite automatizar el procesamiento de datos, minimizando errores humanos y reduciendo el tiempo de revisión. Mediante algoritmos de aprendizaje automático es posible clasificar y priorizar solicitudes en función de criterios predefinidos, lo que facilita un análisis más rápido y preciso.

Además, la implementación de sistemas de IA no sólo optimiza el tiempo de respuesta en la evaluación de solicitudes, sino que también proporciona a los miembros de la comisión de becas herramientas analíticas avanzadas. La IA actúa como un asistente que potencia la capacidad humana, permitiendo que los equipos se dediquen a tareas que requieren juicio y empatía, como el revisar las solicitudes negadas por el sistema.

El uso del método de aprendizaje automático semisupervisado ha demostrado ser adecuado para este contexto, al permitir la explotación de datos etiquetados y no etiquetados. Este enfoque maximiza el rendimiento del modelo, facilitando una mejor identificación de patrones en las solicitudes de becas, lo que resulta crucial para la precisión en la evaluación y decisión sobre la asignación de una solicitud.

Partiendo de la hipótesis de que la implementación de un sistema de IA que recibe un conjunto de datos con variables críticas puede automatizar la toma de decisiones sobre la asignación de becas, se concluye que dicho sistema puede proporcionar una gestión más eficiente y precisa en comparación con los procesos tradicionales. El uso de variables clave, como los ingresos del postulante, el porcentaje solicitado, la capacidad de pago y otros indicadores socioeconómicos, se presenta como un enfoque efectivo para determinar de manera objetiva y justificada si se otorga o no una beca.

La gestión eficiente se alinea con la capacidad de análisis y procesamiento de grandes volúmenes de datos, lo que es esencial para tomar decisiones basadas en evidencia y optimizar el uso de recursos. El MAA, entrenado con datos históricos de solicitudes y otorgamiento de becas, puede identificar patrones y correlaciones entre las variables, facilitando la evaluación objetiva de cada solicitud y reduciendo el margen de error o sesgo humano en la toma de decisiones.

Desde una perspectiva de gestión, este tipo de sistema no sólo reduce la carga de trabajo del comité de becas, sino que también acelera el proceso de toma de decisiones. Al recibir un conjunto de datos estructurados y analizados por IA, las organizaciones pueden acortar significativamente los tiempos de respuesta y, por lo tanto, mejorar la satisfacción de los postulantes. Asimismo, el sistema puede generar reportes detallados que justifiquen las decisiones tomadas, aumentando la transparencia del proceso.

Un sistema de IA que recibe datos con variables clave para decidir la asignación de becas, mejora la eficiencia y la equidad en el proceso, permitiendo a la FCEA gestionar de manera más eficaz los recursos disponibles y responder rápidamente a las necesidades de los postulantes, todo mientras se mantiene la objetividad en la toma de decisiones.

Desde una perspectiva teórica, la automatización del proceso de evaluación de becas mediante un sistema de IA puede significar una revolución en la rapidez con que se toman decisiones sobre la asignación de ayudas económicas. Los MAA, al ser entrenados con datos históricos y actuales, son capaces de identificar patrones y correlaciones que a menudo escapan a la evaluación manual. Esta capacidad de análisis predictivo no sólo acelera el tiempo de respuesta, sino que también incrementa la precisión de las decisiones, reduciendo la subjetividad en el proceso.

Al reducir los tiempos de respuesta, se favorece una experiencia más satisfactoria para los postulantes, quienes podrán conocer con mayor rapidez el resultado de su solicitud. Esto es especialmente relevante en contextos académicos, donde los plazos son estrictos y la incertidumbre puede afectar la planificación educativa de los estudiantes. En definitiva, la mejora en los tiempos de respuesta no sólo optimiza la gestión administrativa, sino que también potencia la confianza de los postulantes en el sistema, contribuyendo a una mayor participación en programas de becas y, por ende.

Para terminar de concluir sobre la tesis, la comisión de becas expresó en la entrevista, que la propuesta de implementar un sistema de IA para automatizar la decisión sobre la asignación de becas es recibida con optimismo y reconocimiento de sus beneficios potenciales. Los miembros de la comisión han señalado que, si bien el proceso actual cumple con su propósito, el uso de un sistema automatizado permitirá una mayor consistencia en la aplicación de criterios y reduciría la subjetividad inherente a la toma de decisiones humanas. Este sistema garantizaría que todas las solicitudes se evalúen bajo los mismos parámetros y sin variaciones debidas a factores externos, como la carga emocional que puede afectar el juicio humano.

Además, la automatización del proceso representaría una significativa mejora en los tiempos de respuesta a las solicitudes. Actualmente, la comisión enfrenta limitaciones debido a la naturaleza honoraria de sus funciones, lo que retrasa las decisiones en períodos de alta carga de trabajo. Un sistema automatizado que analice las variables clave de cada solicitud, como el porcentaje de beca solicitado y los ingresos del postulante, permitiría dar respuestas más rápidas y reduciría la presión sobre los miembros de la comisión.

Los integrantes de la comisión también reconocen el valor emocional de no tener que tomar decisiones que pueden influir directamente en el futuro de los estudiantes. Un sistema automatizado mitigaría esta carga, ya que se basaría en datos objetivos y predeterminados. De esta manera, el comité podría centrarse en tareas de supervisión, en lugar de en la evaluación caso por caso de las solicitudes.

La comisión de becas apoya la implementación de un sistema automatizado utilizando IA para la toma de decisiones en la asignación de becas. Este sistema no sólo agilizaría el proceso y reduciría el margen de error, sino que también ofrecería una mayor equidad y objetividad en la evaluación de los postulantes, todo mientras alivia la carga emocional y operativa de la comisión.

El planteo de esta propuesta de solución corresponde al objetivo general planteado en esta tesis de maestría, analizar e identificar soluciones basadas en inteligencia artificial que optimicen el proceso de otorgamiento de becas para estudiantes de posgrado en la Facultad de Ciencias Económicas y de Administración (FCEA), mejorando su eficiencia, transparencia y equidad.

Una vez realizado este análisis, se podría dar escalabilidad a la solución propuesta. El primer trabajo a futuro que se podría realizar consiste en el diseño y la implementación del sistema de información, definiendo detalladamente su estructura, las entradas que procesarán, las salidas que generará y la forma en que se implementará la inteligencia artificial en su núcleo. Este diseño debe alinearse con el MAA previamente seleccionado, garantizando coherencia y efectividad en su desarrollo e integración.

Una vez implementado el sistema inicial propuesto, se podría integrar un módulo de procesamiento de lenguaje natural (PLN). Este módulo permitiría interpretar automáticamente los datos del formulario, eliminando la necesidad de un etiquetado manual. Esta mejora no solo facilitaría y agilizaría la incorporación de nuevos datos, sino que también garantizaría un flujo continuo de casos de entrenamiento, los cuales son esenciales para mantener y mejorar el rendimiento del algoritmo a lo largo del tiempo. Al alimentar constantemente al modelo con nuevos ejemplos, se optimizan sus variables internas, se descubren patrones adicionales y se refuerza su capacidad de adaptación a escenarios dinámicos. Esto resulta en un sistema más robusto y preciso, capaz de responder con mayor acierto a nuevas solicitudes y desafíos futuros.

10. Referencias bibliográficas y bibliografía

- Ai Lab School. (26 de agosto de 2023). *¿Qué Es El Machine Learning en español?* Ai Lab School: <https://ailabschool.com/que-es-el-machine-learning-en-espanol/>
- Ai Lab Shool. (27 de diciembre de 2022). *¿Cuáles Son Los Tipos De Machine Learning?* AI Lab School: <https://ailabschool.com/cuales-son-los-tipos-de-machine-learning/>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Bleakley, C. (22 de Octubre de 2020). *Poems That Solve Puzzles: The History and Science of Algorithms*. <https://doi.org/https://doi.org/10.1093/oso/9780198853732.001.0001>
- Brynjolfsson, E. H. (2011). Strength in numbers: How does data-driven decision making affect firm performance? *Management Science*, 689-703.
- Cen, H. (s.f.). <https://ailabschool.com/>. 2023: <https://ailabschool.com/cuales-son-los-tipos-de-machine-learning/>
- Fajardo Vargas, J. E. (9 de 9 de 2023). <https://dialnet.unirioja.es.https://dialnet.unirioja.es/servlet/articulo?codigo=9152551>
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow (2nd ed.)*. O'Reilly Media.
- Goodfellow, I. B. (2016). *Deep Learning*. MIT Press.
- <https://dialnet.unirioja.es/>. (6 de 6 de 2023). <https://dialnet.unirioja.es/servlet/articulo?codigo=9152551>
- IBM. (s.f.). IBM. <https://www.ibm.com/mx-es/topics/supervised-learning#:~:text=El%20aprendizaje%20supervisado%2C%20tambi%C3%A9n%20conocido,o%20predigan%20resultados%20con%20precisi%C3%B3n.>
- Kahneman, D. (2003). A perspective on judgment and choice: Mapping bounded rationality. *American Psychologist*, 697-720.
- Kleinberg, J. L. (2017). Discrimination in the age of algorithms. *Journal of Legal Analysis*, 113-174.
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Morandín-Ahuerma, F. (s.f.). <https://philpapers.org/rec/MORQEI-2>
- Morandín-Ahuerma, F. (2022). What is Artificial Intelligence? *Int. J. Res. Publ. Rev*, 1947-1951. <https://philpapers.org/rec/MORQEI-2>
- Ríos, J. (13 de 09 de 2024). *Infobae*. Usarán una IA de Google para decidir si una persona es apta o no para un subsidio de desempleo: <https://www.infobae.com/tecno/2024/09/13/usaran-una-ia-de-google-para-decidir-si-una-persona-es-apta-o-no-para-un-subsidio-de-desempleo/>
- Sackiewicz, L. (23 de 06 de 2022). *Impact Strategy*. Impact Strategy: <https://www.impactstrategy.ai/blog/funciona-la-ia-para-analisis-credito>
- Sampieri Hernández, R. C. (2003). *Capítulo 1. El proceso de investigación y los enfoques cualitativo y cuantitativo: hacia un modelo integral*. México DF: McGraw-Hill Interamericana. <https://highered.mheducation.com:https://highered.mheducation.com/sites/dl/free/1456223968/1058642/CAPITULO04.pdf>
- Simon, H. A. (1991). *Models of my life*. MIT Press.
- Sutton, R. S. (2018). *Reinforcement Learning: An Introduction*. MIT Press.
- Yin, R. (1994). *Case Study Research: Design and Methods*. Sage Publications,.

11. Anexos

11.1. Entrevistas

11.1.1. Entrevista con Silvina Nápoli

Las preguntas planteadas a la coordinadora Silvina Nápoli, fueron las siguientes,

¿Cómo se realiza el análisis para otorgar becas?

Una vez que se cierra el periodo de postulaciones a las distintas becas, se le envían a la comisión de becas para estudiar las distintas solicitudes.

¿Cómo es la conformación de esta comisión de becas?

Esta comisión es honoraria y está formada por los tres órdenes de facultad, orden Estudiantil, orden Docente y orden Egresado.

¿Cómo es el accionar de esta comisión de becas?

Cuando se le pasa la totalidad de las solicitudes, se les entrega también un tiempo límite para cada una de las distintas becas, considerando para este orden de las fechas, las fechas de inicio de los cursos de las diferentes propuestas de posgrados.

Esta comisión estudia cada uno de los casos de las diferentes solicitudes que reciben, parte de este estudio es analizar el porcentaje solicitado por los estudiantes, si este porcentaje supera el 65%, esta solicitud es derivada al consejo de SCEA para su estudio y toma de decisión, si se trata de un porcentaje menor, esta solicitud si será atendida por la comisión.

Pudiendo ellos determinar si se otorga o no, además de eso también pueden proponer un porcentaje diferente al solicitado, en este caso se le responde al postulante que se le podría otorgar otro porcentaje diferente al solicitado y este determina si lo acepta o no.

¿Se puede poner una fecha límite más temprana a la comisión para que dé respuesta a las solicitudes?

Como ya se dijo antes, esta comisión está formada por los tres órdenes y es totalmente honoraria, entonces por este pequeño pero gran detalle de ser honoraria, es que no es posible exigir que den una respuesta para una fecha muy temprana.

Considerando que el cierre de las solicitudes es a fin de año, justamente en este momento es cuando los integrantes de la comisión de becas, tienen una mayor labor en su vida profesional y/o personal, dado que los docentes y estudiantes están con todo lo relativo al fin de los cursos que dictan o reciben. Mientras que los egresados están con los cierres discales de las empresas para las cuales trabajan.

Por lo expuesto es que se torna muy difícil exigirles a los integrantes de la comisión den una respuesta pronta a las solicitudes.

11.1.2. Entrevista con la comisión de Becas

Entrevista a los integrantes de la comisión de becas, esta comisión esta fija y se busca que año a año sean las mismas personas que la integren, ellos son, por el orden egresados Enrique Barla y por el orden docentes Inés Vázquez, no se pudo contar con la participación del integrante del orden estudiantil.

Las preguntas planteadas a los integrantes de la comisión de becas, fueron las siguientes,

¿Cuántas solicitudes de becas hubo para este año?

Este año se recibieron 58 solicitudes de becas, se otorgaron 44, fueron aceptadas y están haciendo uso de las mismas 39 personas.

En los últimos años la cantidad de becas de ayuda económicas otorgadas fueron las siguientes:

Año 2024 - 44
Año 2023 - 34
Año 2022 - 51
Año 2021 - 52
Año 2020 - 62
Año 2019 - 33
Año 2018 - 48

¿Cuántas solicitudes hay aproximadamente cada año?

En los últimos años la cantidad de becas de ayuda económicas solicitadas fueron las siguientes:

Año 2024 - 58
Año 2023 - 42
Año 2022 - 55
Año 2021 - 63

¿Existe algún punto del formulario el cual consideran crucial para SÍ entregar una beca?

Ellos analizan en primera instancia que la persona pueda pagar al menos el 35% del valor total del posgrado al cual se está postulando, porque lo máximo que la facultad puede otorgar es el 65% del monto, esto además lo tienen en cuenta porque el uno de los fines de los posgrados profesionales es la recaudación por parte de facultad.

¿Existe algún punto del formulario el cual consideran crucial para NO entregar una beca?

En este punto consideran lo mismo que en el anterior, los ingresos del postulante, que pueda abonar al menos el 35% de del costo, sino no tiene caso tan siquiera considerarlo porque no se llegaría al total, salvo que solicite un monto mayor, pero en ese caso pasaría la ilicitud al consejo de facultad para su evaluación y determinación.

¿Se tiene un monto fijo con el cual se cuenta para entregar las becas o es algo variable?

El monto con el cual se dispone, es por posgrado y fijo, lo determina los directores de cada posgrado, tienen el estimado de participantes en general, a través de eso estipulan

cuanto podrán dar para becas de esa carrera, luego de finalizada la carrera, evalúan los gastos e ingresos obtenidos en la misma y corrigen lo destinado a becas.

¿Cómo se sentirían si un sistema realiza su tarea como comité de becas?

Ambos integrantes de la comisión, dijeron que sería algo muy bueno si sistema llegara para reemplazar su labor, porque así con eso siempre se aplicaría el mismo criterio, cuestión que ellos reconocen que en la actualidad puede tener pequeñas variaciones.

Además de que ellos también dicen que eso les quitaría parte del peso emocional de ser ellos quienes deciden directamente el futuro de una persona.

11.2. Formulario de solicitud de una beca de apoyo económico en FCEA

A continuación se presenta el formulario de solicitud para una beca de apoyo económica de la FCEA, este formulario es el que se está usando en la actualidad.

DÍA	MES	AÑO

Timbre Profesional \$ 240

DECLARACIÓN JURADA para SOLICITUD DE BECA

Apellido paterno:

Apellido materno:

Nombres:

Cédula de identidad: _____

Maestría/Posgrado al que se postula:

Descuento automático que le corresponde: _____%

Porcentaje de ayuda económica adicional solicitada: _____%

Beca total necesaria para realizar el Programa de Posgrado (A+B): _____%

1. DOCUMENTACIÓN a PRESENTAR

Pasos a seguir:

1. Completar la postulación vía web,
2. Presentar en el Centro de Posgrados la siguiente documentación **en forma personal hasta el 15 de diciembre de 2023 inclusive**
 - 3.1 Carta de Solicitud de Beca o ayuda económica, la que deberá:
 - 3.1.1 Ser dirigida a: Señores Integrantes de la Comisión de Beca,
 - 3.1.2 Especificar las razones que justifican la solicitud de beca, así como el porcentaje total solicitado.
 - 3.2 Adjuntar fotocopia de los recibos de ingresos de los integrantes del núcleo familiar y de los principales egresos, a modo de ejemplo recibo de alquiler o contrato, hipoteca, educación privada de hijos, préstamos sobre sueldo, etc.)
4. Consideraciones generales:
 - 4.1 El postulante, al realizar la solicitud de beca, deberá informar en caso de tener alguna ayuda de la empresa donde trabaja y la Comisión de Beca decidirá en cada caso. Si no tiene conocimiento de lo anterior, al momento de presentar la solicitud, cuándo lo sepa deberá comunicarlo y la Comisión de Beca podrá reevaluar lo otorgado ya que cambia su situación.
En síntesis:
 - 4.2 Los estudiantes que reciban algún apoyo económico de su empresa, deberán comunicarlo tan pronto lo sepan, a la Comisión de Becas;
 - 4.3 La Comisión de Becas podrá reevaluar la ayuda económica otorgada modificándola.

2. DATOS PERSONALES DEL POSTULANTE

Fecha de nacimiento: ____/____/____ Edad: ____ años

M

Sexo: F ☐ ☐

Teléfono fijo: _____ Celular: _____

Email:

Lugar de nacimiento:

Dirección actual:

Ciudad: _____ Departamento:

Estado civil:

Soltero ☐ Casado ☐ Unión libre ☐ Divorciado ☐ ☐

Viudo

☐

Hijos: _____ Edades:

3. INSTITUCIONES EDUCATIVAS

3.1 Bachillerato: Pública ☐ Privada ☐

Institución _____ educativa:

Tenía beca? NO ☐ SÍ ☐ Porcentaje: _____%

3.2 Carrera de grado: Pública ☐ Privada ☐

Institución _____ educativa:

Tenía beca en la institución privada? NO ☐ SÍ ☐

Porcentaje: _____%

4. SITUACIÓN LABORAL

4.1 Institución / Empresa donde trabaja

4.2 Desde: _____

4.3 Cargo que ocupa:

4.4 Dirección:

—

4.5 Teléfonos:

—

5. SITUACIÓN SOCIO-ECONÓMICA

5.1 Número de integrantes del Núcleo Familiar del postulante

(incluyendo al postulante): _____

5.2 Detalle de integrantes de Núcleo Familiar (que viven bajo el mismo techo):

Relación familiar	Edad

6. SITUACIÓN PATRIMONIAL DEL POSTULANTE

6.1 Bienes Inmuebles

6.1.1 Es propietario de la casa en que vive: Sí ☐ ☐

6.1.1.1 Dirección:

6.1.1.2 Superficie construida (m2): _____

6.1.1.3 Valor comercial: U\$S _____

6.1.1.4 En caso pagar préstamo hipotecario, cuota mensual: U\$S / \$

6.1.2 Otras propiedades

6.1.2.1 Direcciones:

6.1.2.2 Superficies (m²/há): _____ _____ _____

6.1.2.3 Valores comerciales: U\$S _____

6.1.3 Vehículos

6.1.3.1 Marca: _____ Modelo: _____ Año: ____ Valor U\$S:

6.1.3.2 Marca: _____ Modelo: _____ Año: ____ Valor U\$S:

6.1.3.3 Marca: _____ Modelo: _____ Año: ____ Valor U\$S:

7. SITUACIÓN PATRIMONIAL DEL NÚCLEO FAMILIAR DEL POSTULANTE

7.1 Bienes Inmuebles

7.1.1 Dirección:

7.1.1.1 Superficie construida (m2): _____

7.1.1.2 Valor comercial: U\$S _____

7.1.1.3 En caso pagar préstamo hipotecario, cuota mensual: U\$S / \$

7.1.2 Otras propiedades

7.1.2.1 Direcciones:

7.1.2.2 Superficies contruídas (m2/há): _____

7.1.2.3 Valores comerciales: U\$S _____

7.1.3 Vehículos

7.1.3.1 Marca: _____ Modelo: _____ Año: ____ Valor U\$S:

7.1.3.2 Marca: _____ Modelo: _____ Año: ____ Valor U\$S:

8. INGRESOS Y EGRESOS DEL NÚCLEO FAMILIAR DEL POSTULANTE

INGRESOS FAMILIARES NÚCLEO FAMILIAR		EGRESOS FAMILIARES NÚCLEO FAMILIAR	
Líquido del Postulante en Institución/Empresa		Alquiler o cuota vivienda	
Líquido del Postulante por actividad profesional libre (promedio mensual)		Educación hijos/cónyuges/postulante (aclarar)	
Otros ingresos líquidos del postulante (promedio mensual)		Gastos comunes	
Cónyuge o integrante unión libre		UTE	
Madre		OSE	
Padre		ANTEL / ADSL	
Hermanos o quienes corresponda		GAS	
		CELULAR	
		Contribución Inmobiliaria (mensual)	
Ingresos por rentas		Patente y seguro auto (mensual)	
Otros ingresos (aclarar)		Cuotas Club/Gimnasio	
		Vestimenta	
		Alimentación	
		Otros (aclarar)	
TOTAL INGRESOS \$		TOTAL EGRESOS \$	

* El formulario precedente constituye una Declaración Jurada de todos los datos volcados en el mismo.

** En todos los casos las becas se otorgarán condicionadas al buen rendimiento del postulante.

Aclaración de firma: _____

Fecha: