

Treball de Fi de Grau

Títol

Eina de recomanació cinematogràfica
basada en emocions a través
d'intel·ligència artificial

Autoria

Dídac Taulats Braos

Professorat tutor

Michele Catanzaro

Grau

Comunicació Audiovisual	
Periodisme	
Publicitat i Relacions Públiques	
Comunicació Interactiva	X
Comunicació de les Organitzacions	

Tipus de TFG

Projecte	X
Recerca	

Data

Del 10 al 13 de juny de 2025	X
De l'1 al 2 de setembre de 2025	

Full resum del TFG

Títol del Treball Fi de Grau:

Català:	Eina de recomanació cinematogràfica basada en emocions a través d'intel·ligència artificial			
Castellà:	Herramienta de recomendación cinematográfica basada en emociones a través de inteligencia artificial			
Anglès:	An Emotion-Driven Film Recommendation System Based on Artificial Intelligence			
Autoria:		Dídac Taulats Braos		
Professorat tutor:		Michele Catanzaro		
Curs:	2024/25	Grau:	Comunicació Audiovisual	
			Periodisme	
			Publicitat i Relacions Públiques	
			Comunicació Interactiva	X
			Comunicació de les Organitzacions	

Paraules clau (mínim 3)


Català:	recomanació, emocions, intel·ligència artificial, cinema, anàlisi de sentiments
Castellà:	recomendación, emociones, inteligencia artificial, cine, análisis de sentimientos
Anglès:	recommendation, emotions, artificial intelligence, cinema, sentiment analysis

Resum del Treball Fi de Grau (extensió màxima 100 paraules)

Català:	Aquest treball presenta una eina de recomanació cinematogràfica basada en l'anàlisi de sentiments extrets d'un text introduït per l'usuari. Utilitzant tècniques d'intel·ligència artificial i una base de dades externa, el sistema genera suggeriments personalitzats segons l'estat emocional expressat. A diferència dels sistemes tradicionals, aquest prototip prioritza la dimensió emocional com a criteri de recomanació. El projecte també aborda la seva viabilitat tècnica, escalabilitat i possibilitats de comercialització en entorns reals.
---------	---

Castellà:	Este trabajo presenta una herramienta de recomendación cinematográfica basada en el análisis de sentimientos extraídos de un texto introducido por el usuario. Utilizando técnicas de inteligencia artificial y una base de datos externa, el sistema genera sugerencias personalizadas según el estado emocional expresado. A diferencia de los sistemas tradicionales, este prototipo prioriza la dimensión emocional como criterio de recomendación. El proyecto también analiza su viabilidad técnica, escalabilidad y posibilidades de comercialización en entornos reales.
Anglès:	This project presents a film recommendation tool based on sentiment analysis extracted from user-provided text. Using artificial intelligence techniques and an external movie database, the system generates personalized suggestions according to the expressed emotional state. Unlike traditional recommendation systems, this prototype emphasizes emotional input as the main recommendation criterion. The project also explores its technical feasibility, scalability, and potential for commercialization in real-world applications.

Eina de recomanació cinematogràfica basada en emocions a través d'intel·ligència artificial



Resum

Aquest treball presenta una eina de recomanació cinematogràfica basada en l'anàlisi de sentiments extrets d'un text introduït per l'usuari. Utilitzant tècniques d'intel·ligència artificial i una base de dades externa, el sistema genera suggeriments personalitzats segons l'estat emocional expressat. A diferència dels sistemes tradicionals, aquest prototip prioritza la dimensió emocional com a criteri de recomanació. El projecte també aborda la seva viabilitat tècnica, escalabilitat i possibilitats de comercialització en entorns reals.

Abstract

This project presents a film recommendation tool based on sentiment analysis extracted from user-provided text. Using artificial intelligence techniques and an external movie database, the system generates personalized suggestions according to the expressed emotional state. Unlike traditional recommendation systems, this prototype emphasizes emotional input as the main recommendation criterion. The project also explores its technical feasibility, scalability, and potential for commercialization in real-world applications.

Agraïments

Gràcies a totes aquelles persones que s'han preocupat per mi i per aquest treball durant la seva realització. Gràcies a Michele Catanzaro, el meu tutor per guiar-me acadèmicament durant el treball. Gràcies a la mare i al pare per ser la meva llum. Gràcies a Déu tot ha sortit bé.

Índex de continguts

Resum	i
Abstract	i
Agraïments	ii
1. Introducció	5
1.1. Objectius.....	6
2. Marc teòric.....	7
2.1. Anàlisi de sentiments.....	7
2.1.1. Definició	7
2.1.2. Detecció de sentiments	7
2.1.3. Problemes de l'anàlisi de sentiments	8
2.2. Sistemes de recomanació	9
2.2.1. Definició	9
2.2.2. Tipus de sistemes de recomanació.....	10
2.2.3. Intel·ligència artificial als sistemes de recomanació	15
2.2.4. Problemes ètics de la intel·ligència artificial	16
3. Antecedents	18
3.1. Entrevista amb l'equip de Filmin	20
3.2. Limitacions i oportunitats del model de recomanació de Filmin	21
4. Metodologia.....	23
4.1. Eines utilitzades	23
4.1.1. API usada	23
4.2. Obtenció de les dades	26
4.3. Programació.....	28
5. Pla d'exploració	34

5.1.	Validació i testatge amb expertes.....	34
5.2.	Proposta de valor	36
5.3.	Públic objectiu.....	36
5.4.	Anàlisi de mercat.....	36
5.5.	Anàlisi de la competència	37
5.6.	Model de negoci.....	38
5.7.	Estratègia de comunicació i comercialització	38
5.8.	Pressupost estimat	39
5.9.	Viabilitat tècnica.....	40
5.10.	Escalabilitat.....	41
5.10.1.	Futures funcionalitats.....	41
5.11.	Aspectes legals i ètics.....	43
6.	Conclusions	44
7.	Bibliografia.....	46
	Annexos.....	50

Índex de taules

Taula 1. Puntuacions de productes. Elaboració pròpia.....	11
Taula 2. Nombre de títols disponibles per plataforma. Elaboració pròpia.	26
Taula 3. Gèneres seleccionats per emoció. Elaboració pròpia.....	31
Taula 4. Cost estimat d'una MVP. Elaboració pròpia.	40

Índex d'il·lustracions

Il·lustració 1. Interfície de Netflix. Font: Netflix.....	19
Il·lustració 2. Interfície de Filmin. Font: Filmin.....	27
Il·lustració 3. Diagrama dels processos del prototip. Elaboració pròpia.....	28
Il·lustració 4. Llista de pel·lícules vistes per la usuària Elaboració pròpia	31
Il·lustració 5. Interfície general del prototip. Elaboració pròpia	32
Il·lustració 7. Evolució trimestral del nombre de subscriptors de Netflix arreu del món (2013–2024). Font: Statista	37

1. Introducció

Aquest treball neix de l'interès personal d'un aficionat al cinema, un aficionat al qual li preocupa el que passa al seu entorn i que, com a membre de la generació Z, sovint es troba immers en un sistema saturat d'informació. Tot i tenir accés immediat a una gran quantitat de contingut audiovisual, sovint li resulta difícil decidir què consumir. Aquesta dificultat, compartida amb moltes altres persones, ha estat el punt de partida per desenvolupar una eina que ajudi a fer recomanacions cinematogràfiques més personalitzades i significatives.

En un context on les plataformes de streaming ofereixen milers de títols i on el temps de la persona usuària és limitat, la presa de decisions s'ha convertit en una tasca cada cop més complexa. Aquesta situació ha generat l'interès de moltes empreses tecnològiques per desenvolupar sistemes de recomanació més sofisticats. No obstant això, molts d'aquests sistemes es basen únicament en el comportament de consum previ o en puntuacions, deixant de banda la dimensió emocional del moment de consum.

Aquest projecte proposa una aproximació alternativa: utilitzar l'anàlisi de sentiments com a punt de partida per oferir recomanacions cinematogràfiques més empàtiques i contextualitzades. Així, es pretén explorar com les emocions expressades per les usuàries poden servir com a base per suggerir pel·lícules que connectin millor amb el seu estat d'ànim.

A més d'abordar un repte cada vegada més comú en el consum cultural digital, aquest treball pretén aportar una proposta innovadora combinant tècniques d'intel·ligència artificial amb l'experiència emocional de la usuària. La recomanació basada en sentiments representa una alternativa al model clàssic de recomanació per historial o puntuació, i pot contribuir a oferir experiències més empàtiques i personalitzades.

El desenvolupament del projecte s'ha basat en una combinació d'estudi teòric, disseny i implementació d'un prototip funcional, i recerca aplicada. Així mateix, s'ha realitzat una entrevista amb l'equip de Filmin per contrastar la proposta amb la realitat del sector i obtenir una visió professional sobre la seva viabilitat i aplicabilitat.

Al llarg d'aquest treball s'abordarà, des d'un punt de vista teòric, l'anàlisi de sentiments i els sistemes de recomanació, així com els antecedents relacionats amb aquests àmbits. També s'inclourà l'anàlisi de l'entrevista amb Filmin. Des d'una perspectiva pràctica, s'explicarà com s'ha desenvolupat el

prototip d'una eina de recomanació cinematogràfica basada en sentiments. Finalment, es presentarà un pla d'explotació que analitzarà la viabilitat del prototip i explorarà possibles vies de comercialització i internacionalització. El treball conclourà amb una reflexió general sobre els resultats obtinguts i les possibles línies de futur per a aquest tipus de solucions. Els objectius específics del treball es detallen a continuació.

1.1. Objectius

L'objectiu principal d'aquest treball és desenvolupar un prototip funcional d'un sistema de recomanació cinematogràfica que, a diferència dels sistemes tradicionals, tingui en compte les emocions de la usuària com a criteri central per generar recomanacions personalitzades.

Per assolir aquest objectiu general, es plantegen els següents objectius específics:

- Analitzar el funcionament dels sistemes de recomanació actuals, especialment en l'àmbit de les plataformes de streaming.
- Investigar com s'aplica l'anàlisi de sentiments en el camp de la intel·ligència artificial i explorar les seves possibilitats dins del sector cultural.
- Dissenyar i implementar un prototip que combini l'anàlisi emocional d'un text escrit per la usuària amb un algorisme de recomanació de pel·lícules.
- Avaluar la viabilitat d'aquesta proposta mitjançant una entrevista amb l'equip de Filmin, amb l'objectiu d'entendre com es podrien integrar eines d'aquest tipus en plataformes reals.
- Elaborar un pla d'explotació que contempli possibles escenaris de comercialització i internacionalització del prototip desenvolupat.

2. Marc teòric

En aquest segon bloc s'abordaran, des d'un punt de vista teòric, l'anàlisi de sentiments, els sistemes de recomanació i com la intel·ligència artificial té un paper crucial dins d'aquestes dues temàtiques.

2.1. Anàlisi de sentiments

2.1.1. Definició

L'anàlisi de sentiments, o mineria d'opinions, és una subdisciplina dins del camp del processament del llenguatge natural (NLP, *Natural Language Processing*), que consisteix en un procés en què, en analitzar un gran volum de text, un algorisme determina si s'està expressant un missatge positiu, negatiu o neutre. Aquest terme, que va ser batejat per primer cop el 2003, es continua explotant fins al dia d'avui, a causa de tres punts clau: els avenços de l'aprenentatge automàtic, la gran quantitat de dades i el fàcil accés a aquestes i, en últim lloc, la gran varietat d'usos que se li pot donar a aquesta anàlisi (Pang, 2008), que van des del comerç en línia fins a la investigació o el seguiment dels mitjans de comunicació.

Els algoritmes d'anàlisi de sentiments poden basar-se en mètodes supervisats, no supervisats o combinacions d'ambdós. Els mètodes supervisats utilitzen conjunts de dades etiquetades per entrenar models de classificació, mentre que els no supervisats es basen en diccionaris de paraules amb polaritat predefinida per determinar el to d'un text (Lighthart, Catal & Tekinerdogan, 2021).

L'aplicació d'aquestes tècniques s'ha expandit a nombrosos sectors, com la política (per analitzar l'opinió pública sobre candidats i mesures governamentals), la salut (per detectar patrons emocionals en pacients) i l'atenció al client (per comprendre la satisfacció de les usuàries en empreses i serveis), entre molts altres.

2.1.2. Detecció de sentiments

La detecció de sentiments és el procés mitjançant el qual un sistema automatitzat analitza i classifica un text segons la seva càrrega emocional. Aquesta anàlisi es pot fer a diversos nivells, com ara paraules, frases, documents sencers o fins i tot converses senceres en xarxes socials.

2.1.2.1. Mètodes de detecció

Els principals mètodes per a la detecció de sentiments es poden classificar en dos grans grups, cadascun dels quals es relaciona amb els tipus d'algorismes comentats anteriorment, els supervisats i els no supervisats:

- Basats en diccionaris o lèxics: Aquest mètode es correspon amb els algorismes no supervisats, ja que es basa en l'ús de llistes predefinides de paraules associades a sentiments positius o negatius. Per exemple, termes com “fantàstic” o “horrible” poden indicar clarament l'emoció expressada. Tot i això, és un mètode limitat, perquè si una paraula no apareix al diccionari, no es pot interpretar, i sovint no és capaç de captar contextos més complexos o matisos com la ironia.
- Basats en aprenentatge profund: Aquests mètodes, habitualment supervisats, utilitzen xarxes neuronals com les basades en Transformers, per exemple BERT (*Bidirectional Encoder Representations from Transformers*). BERT és especialment adequat per a l'anàlisi de textos, ja que interpreta tant el context anterior com el posterior d'una paraula, cosa que permet distingir significats segons el context, com en la frase “El banc és al costat de l'estació”. Per contra, el model GPT (*Generative Pre-trained Transformer*) és unidireccional i, com que és una IA generativa, només té en compte el que precedeix la paraula que analitza (Salıcı & Ölçer, 2024). Encara que GPT no és tan bo per a la detecció de sentiments com BERT, continua sent un model molt conegut i utilitzat. En qualsevol cas, tant BERT com GPT poden captar matisos i ironies en els textos, cosa que millora la precisió de l'anàlisi.

2.1.3. Problemes de l'anàlisi de sentiments

Tot i els avenços en aquest camp, la detecció de sentiments encara presenta diversos desafiaments que poden afectar la seva precisió i efectivitat.

- Ironia i sarcasme. Molts sistemes tenen dificultats per detectar l'ús de la ironia i el sarcasme, ja que el significat literal del text no sempre reflecteix la intenció real de l'autor. Per exemple, la frase “Quina pel·lícula més increïble... No he pogut parar de badallar!” pot ser etiquetada erròniament com a positiva.

- Context i ambigüitat. Un mateix terme pot tenir diferents significats segons el context. La paraula “fred”, per exemple, pot tenir connotacions negatives quan es parla d’un restaurant (per indicar mala qualitat del menjar) però neutres o positives quan es parla d’un clima desitjat.
- Llenguatge informal i emojis. Les xarxes socials i missatgeria instantània han popularitzat l’ús d’abreviatures, emojis i argot, cosa que pot dificultar la interpretació dels sentiments. Per exemple, “molt bona pel·li 🤩” podria indicar entusiasme, però també sarcasme, segons el context.
- Biaixos en els models. Els sistemes d’aprenentatge automàtic poden estar afectats per biaixos en les dades d’entrenament, fet que pot conduir a interpretacions incorrectes. Per exemple, si un model ha estat entrenat principalment amb ressenyes en anglès, podria no interpretar correctament les estructures i expressions pròpies d’altres idiomes o dialectes. En el següent apartat, s’aprofundirà més en aquest tema.

2.2. Sistemes de recomanació

2.2.1. Definició

Des de l’aparició de la web 2.0, l’any 2004, en què les usuàries dels blogs i, més tard, de les xarxes socials es converteixen en els principals productes d’aquestes (Latorre, 2018), es crea una nova necessitat de mostrar contingut constantment per mantenir les usuàries entretingudes. Apareix un gran nombre d’aplicacions capaces de predir les respostes a preguntes que la usuària es planteja en entrar al lloc web: els sistemes de recomanació. Aquests sistemes, tot i que en aquest treball s’aprofundirà en la cinematografia, també inclouen models capaços de predir productes o serveis, música, entre altres. Poder automatitzar aquests processos mitjançant aprenentatge automàtic afavoreix en gran manera l’increment del nombre de vendes, la satisfacció de les usuàries, la fidelitat dels mateixos i entendre millor què és el que volen i necessiten (Pérez & Close, 2015).

Encara que des dels anys noranta s’investiga en aquest àmbit, a causa de tot el nou contingut que s’anava compartint en línia i per poder veure en perspectiva la importància que li donen aquestes plataformes, l’any 2007 Netflix va organitzar un concurs amb un premi d’1.000.000 \$ per a qui pogués crear un sistema de recomanació un 10% més eficient que el que utilitzaven fins aquell moment, guanyant-lo un equip d’investigadors que es diu “Bellkorp’s Pragmatic Chaos” l’any 2009, després de tres

anys dins el concurs (Leskovec, Rajaraman & Ullman, 2020). A més de Netflix, les webs i plataformes amb sistemes de recomanació més populars i òptims són Amazon, YouTube, Yahoo, Tripadvisor, Last.fm i IMDB (González & Jacques, 2017).

2.2.2. Tipus de sistemes de recomanació

Hi ha diversos tipus de sistemes de recomanació en funció dels filtres utilitzats. A continuació, es mencionen tres tipus principals: el filtratge basat en contingut, el filtratge col·laboratiu i el filtratge híbrid, juntament amb les seves característiques.

2.2.2.1. Filtratge basat en contingut

El filtratge basat en contingut (*Content-Based Filtering*, CBF) recomana productes que s'ajustin al perfil de la usuària. Aquest perfil es pot construir de manera explícita, preguntant-li quines són les seves preferències mitjançant un formulari. Per exemple, després de veure una pel·lícula, se li pot demanar que hi afegeixi una valoració per tal de recomanar-li després altres films similars. També es pot construir de manera implícita, analitzant les seves accions dins la plataforma per detectar si el contingut que està visualitzant li agrada o no (González & Jacques, 2017). Aquesta informació s'obté a través de les molt mencionades galetes, definides com a petites unitats d'informació que s'emmagatzemen al navegador de la usuària i proporcionen dades als desenvolupadors de la plataforma sobre el seu comportament (Marcos Poza, 2019).

Alguns exemples de la informació que les plataformes obtenen són: quant de temps passa una usuària visualitzant cada vídeo en una aplicació de contingut vertical, quant de temps roman en una mateixa pantalla en un comerç electrònic, o si ha interactuat amb un producte afegint-lo al carret de la compra o a la secció de "veure més tard". També es poden registrar dades sobre la seva procedència, per exemple, si arriba des d'un navegador, una xarxa social o una altra pàgina web.

Aquesta tècnica dona molt bons resultats, ja que permet combinar diferents tipus d'informació: els gustos de les usuàries, les funcionalitats de la plataforma i les característiques dels productes que es volen vendre. L'única problemàtica és que és difícil d'implementar i mantenir, perquè no totes les usuàries estan disposades a crear aquest perfil virtual o a permetre que les *cookies* ho facin per elles. A més, el sistema ha d'actualitzar-se constantment per garantir que es disposi sempre de la màxima informació possible (González & Jacques, 2017).

2.2.2.2. Filtratge col·laboratiu

El filtratge col·laboratiu (Collaborative Filtering, CF) fa la recomanació des d'un altre punt de vista. En comptes de fer recomanacions a partir dels continguts, com el CBF, ho fa a partir de l'opinió de diferents usuàries sobre aquests productes. És a dir, ens fem constantment la següent pregunta: si a una usuària 1 li ha agradat el producte 1, li agradarà també el 3? Aquesta qüestió es respon amb les valoracions de les usuàries que han puntuat de manera similar la primera pel·lícula. A continuació, s'il·lustrarà un exemple.

	Producte 1	Producte 2	Producte 3	Producte 4	Producte 5
Usuària 1	5	4	?	2	3
Usuària 2	4	3	5	1	2
Usuària 3	2	3	2	5	4
Usuària 4	5	4	4	2	3
Usuària 5	3	2	3	4	5
0 = Puntuació més baixa. 5 = Puntuació més alta.					

Taula 1. Puntuacions de productes. Elaboració pròpia.

Per poder determinar si a la Usuària 1 li agradarà el Producte 3, necessitem utilitzar dues fórmules: la fórmula de similitud del cosinus i la fórmula de predicció ponderada (Olguín, G. E. M., & De Jesús, Y. L., 2019). La primera mesura com d'alineats estan els vectors de qualificacions de dues usuàries, i la segona és capaç de predir la puntuació d'un producte segons les puntuacions d'usuàries similars.

$$\text{sim}(U1, Ux) = \frac{\sum(r_{U1,p} \cdot r_{Ux,p})}{\sqrt{\sum r_{U1,p}^2} \cdot \sqrt{\sum r_{Ux,p}^2}} \quad r_{U1,p3} = \frac{\sum(\text{sim}(U1, Ux) \times r_{Ux,p3})}{\sum \text{sim}(U1, Ux)}$$

On:

- $\sum$ és sumatori
- r és la puntuació
- U és la usuària
- p és el producte

Primer de tot, calculem la magnitud de la Usuària 1, que es determina mitjançant l'arrel quadrada de la suma de les puntuacions de cada producte elevades al quadrat. És a dir:

$$|U1| = \sqrt{5^2 + 4^2 + 2^2 + 3^2} = \sqrt{25 + 16 + 4 + 9} = \sqrt{54} \approx 7.35$$

I després amb la resta de les usuàries:

$$|U2| = \sqrt{4^2 + 3^2 + 5^2 + 1^2 + 2^2} = \sqrt{16 + 9 + 25 + 1 + 4} = \sqrt{55} \approx 7.42$$

$$|U3| = \sqrt{2^2 + 3^2 + 2^2 + 5^2 + 4^2} = \sqrt{4 + 9 + 4 + 25 + 16} = \sqrt{58} \approx 7.62$$

$$|U4| = \sqrt{5^2 + 4^2 + 4^2 + 2^2 + 3^2} = \sqrt{25 + 16 + 16 + 4 + 9} = \sqrt{70} \approx 8.37$$

$$|U5| = \sqrt{3^2 + 2^2 + 3^2 + 4^2 + 5^2} = \sqrt{9 + 4 + 9 + 16 + 25} = \sqrt{63} \approx 7.94$$

Un cop calculades les magnituds de cada usuària, ja podem calcular la similitud entre la Usuària 1 i la resta.

Usuària 1 i 2:

$$(5 \times 4) + (4 \times 3) + (2 \times 1) + (3 \times 2) = 20 + 12 + 2 + 6 = 40$$

$$\text{sim}(U1, U2) = \frac{40}{(7.35 \times 7.42)} = \frac{40}{54.55} \approx 0.733$$

Usuària 1 i 3:

$$(5 \times 2) + (4 \times 3) + (2 \times 5) + (3 \times 4) = 10 + 12 + 10 + 12 = 44$$

$$\text{sim}(U1, U3) = \frac{44}{(7.35 \times 7.62)} = \frac{44}{56.02} \approx 0.785$$

Usuària 1 i 4:

$$(5 \times 5) + (4 \times 4) + (2 \times 2) + (3 \times 3) = 25 + 16 + 4 + 9 = 54$$

$$\text{sim}(U1, U4) = \frac{54}{(7.35 \times 8.37)} = \frac{54}{61.52} \approx 0.877$$

Usuària 1 i 5:

$$(5 \times 3) + (4 \times 2) + (2 \times 4) + (3 \times 5) = 15 + 8 + 8 + 15 = 46$$

$$\text{sim}(U1, U5) = \frac{46}{(7.35 \times 7.94)} = \frac{46}{58.38} \approx 0.788$$

Amb aquests resultats, podem veure, en una escala de 0 a 1, quina usuària té les puntuacions més pròximes a la Usuària 1. En aquest cas, és la Usuària 4, amb una similitud de 0,877 aproximadament.

Sabent aquests resultats, també podem predir quina puntuació aproximada donarà la Usuària 1 al Producte 3, gràcies a la fórmula de predicció ponderada.

$$r_{U1,P3} = \frac{(0.733 \times 5) + (0.785 \times 2) + (0.877 \times 4) + (0.788 \times 3)}{0.733 + 0.785 + 0.877 + 0.788}$$
$$r_{U1,P3} = \frac{3.665 + 1.57 + 3.508 + 2.364}{3.183}$$
$$r_{U1,P3} = \frac{11.107}{3.183} \approx 3.49$$

Després de calcular-ho, descobrim que la puntuació aproximada del Producte 3 seria de 3,49, un resultat esperable tenint en compte que la usuària més propera a aquesta era la Usuària 4, que l'havia puntuat amb una qualificació de 4.

Aquest model de filtratge, tot i ser el més popular i estès, comporta una sèrie de problemàtiques. Per començar, aquest exemple tracta un problema amb cinc usuàries, cinc productes i una única incògnita, un cas molt simple i clar per entendre el procés que es duu a terme cada cop. Però en una situació real, ens trobem que en una plataforma com Amazon (en el cas del comerç en línia) o Filmin (en les plataformes de streaming), hi ha milers de productes o pel·lícules, milers d'usuàries i que els productes valorats només representen un percentatge molt petit del total. Això fa que tots aquests càlculs siguin molt més abstractes del que podrien semblar a l'exemple anterior.

A més, també se'ns presenta una segona problemàtica: l'arrencada en fred (*Cold Start*). Aquest concepte fa referència, sobretot, a l'inici de l'entrenament d'un algorisme d'aquesta mena, quan ens trobem que no hi ha usuàries que hagin puntuat o valorat tots els productes. Llavors, l'algorisme ha de calcular les puntuacions de cada pel·lícula sense prou dades per fer-ho.

Juntament amb aquest problema, n'apareix un tercer relacionat amb el filtratge col·laboratiu: el cost computacional necessari per calcular, cada cop, totes les pel·lícules que poden agradar més o menys simultàniament a cadascuna de les usuàries connectades. Aquest cost és molt elevat i, per això, s'introdueix el concepte de Cua Llarga (*Long Tail*). Aquesta tècnica consisteix a tenir en compte i calcular només aquelles puntuacions que l'algorisme preveu que seran més altes. És a dir, si a una usuària només li agraden 500 pel·lícules, per què hauríem d'usar l'eina per predir si li agradarien les més de 17.000 sèries i pel·lícules disponibles a Netflix, quan ja “sabem” la resposta?

2.2.2.3. Filtratge híbrid

El filtratge híbrid (Hybrid Filtering, HF), com bé diu la paraula, implementa dos models de recomanació alhora per obtenir resultats òptims. Si agaféssim els models ja esmentats, faria una recomanació a base de contingut (CBF) i tindria en compte els continguts que consumeixen simultàniament les altres usuàries (CF) per tenir en tot moment una visió holística de cada usuària (Ebesu, 2019).

Aquest enfocament permet combinar els avantatges dels dos models i mitigar-ne les limitacions. Per exemple, el filtratge basat en contingut (CBF) sovint pateix del problema de la sobreespecialització, ja que només recomana elements similars als que la usuària ja ha consumit. D'altra banda, el filtratge col·laboratiu (CF) pot tenir dificultats amb l'efecte fred, on les usuàries o elements nous no tenen prou dades per generar recomanacions precises.

Mitjançant tècniques de filtratge híbrid, es poden implementar diverses estratègies:

- Combinació ponderada: Un model híbrid ponderat que utilitza l'aprenentatge d'acoblament ha estat proposat per millorar el rendiment predictiu dels sistemes de recomanació. Mitjançant un mètode de combinació ponderada per suma, aquest enfocament integra el CBF i el CF per aconseguir prediccions més precises. Els estudis demostren que aquest model híbrid ofereix una millor precisió amb valors més baixos d'error (Yang, Jang & Kim, 2020).
- Enfocament seqüencial: En la previsió de sèries temporals, s'ha introduït un model seqüencial ponderat per superar les limitacions dels models que assumeixen pesos iguals per als components. Aquest model modela seqüencialment els components i calcula pesos òptims mitjançant mínims quadrats, la qual cosa dona com a resultat una millor precisió (Hajirahimi & Khashei, 2019).
- Model unificat: Utilitza màquines unificades de Boltzmann, que combinen informació col·laborativa i basada en contingut. Aquest mètode pondera automàticament diferents tipus d'informació i ofereix bons resultats tant per articles vistos com en situacions d'arrencada en fred (Gunawardana & Meek, 2009).

Aquest tipus de sistemes híbrids han estat usats per plataformes com Netflix o Spotify per oferir recomanacions més precises i adaptades als interessos de les usuàries.

2.2.3. Intel·ligència artificial als sistemes de recomanació

La intel·ligència artificial (IA) ha esdevingut una peça clau dins del desenvolupament dels sistemes de recomanació més avançats. A diferència dels models tradicionals basats exclusivament en regles predefinides o estadístiques simples, els sistemes impulsats per IA poden aprendre i adaptar-se automàticament al comportament de la usuària, millorant constantment les seves prediccions a mesura que es recullen noves dades.

Els models més habituals utilitzen tècniques d'aprenentatge automàtic (*machine learning*) i, en etapes més avançades, aprenentatge profund (*deep learning*). Aquestes tècniques permeten extreure patrons complexos del comportament de les usuàries, tenint en compte múltiples fonts d'informació: preferències prèvies, context temporal, dispositius usats, patrons de consum i, en casos més recents, fins i tot l'estat emocional.

Un exemple representatiu de l'ús de la IA són les xarxes neuronals multicapa o convolucionals, que poden analitzar grans volums de dades per predir quins continguts són més rellevants per a cada perfil. Plataformes com YouTube, Netflix o Spotify utilitzen sistemes de recomanació que incorporen aquests models per ajustar dinàmicament la seva interfície, suggeriments i ordres de reproducció (Isita, 2024; Holgado, 2023).

A més, l'ús de transformers, com ara BERT o GPT, ha permès un salt qualitatiu en la capacitat dels sistemes per entendre millor el llenguatge natural i, per tant, el context i la intenció de les usuàries quan escriuen opinions o comentaris. Això obre la porta a recomanacions basades en el contingut textual expressat en ressenyes, missatges o fins i tot emocions, tal com explora aquest mateix treball.

Un altre àmbit emergent és l'ús de sistemes de reforç (*reinforcement learning*), que permeten que l'algoritme vagi aprenent a partir de la interacció directa amb la usuària, de manera similar a com un assistent personal optimitza el seu comportament en funció dels comentaris rebuts.

Finalment, cal destacar que la IA no només ajuda a fer prediccions més precises, sinó que també permet que els sistemes siguin més contextuals, personalitzats i proactius, adaptant-se a l'estat d'ànim, al moment del dia o al canal d'accés de la usuària. Així, es transforma una simple eina de suggeriment en una experiència personalitzada i emocionalment significativa.

2.2.4. Problemes ètics de la intel·ligència artificial

Els models d'intel·ligència artificial presenten una sèrie de problemàtiques que, tot i els intents per solucionar-les, són difícils d'eliminar completament.

L'ètica i els biaixos de les dades que es volen interpretar sovint estan marcats per prejudicis i discriminacions, sobretot en àmbits racials, de gènere i religiosos. Aquestes problemàtiques es poden observar en casos concrets, com el d'Amazon i el de la policia de Detroit. Encara que aquests exemples no corresponen exactament a sistemes de recomanació tradicionals, il·lustren clarament com els biaixos en les dades poden afectar greument les decisions automatitzades, com les que fan els sistemes de recomanació.

En el primer cas, Amazon, el 2014, va començar a implementar sistemes amb IA que recomanaven a l'empresa si havia de contractar una persona basant-se en el seu currículum. En un principi, semblava un sistema molt eficient per a l'empresa, però un any després, el 2015, es van adonar que no era imparcial a l'hora de seleccionar els perfils aptes. Si en un d'aquests apareixia en alguna part la paraula “dona” o “femení”, com per exemple “capitana de l'equip femení d'escacs”, l'algorisme descartava automàticament aquella persona. En canvi, valorava positivament verbs com “executat” i “capturat”, termes majoritàriament utilitzats per enginyeres de sexe masculí (The Guardian, 2018).

El segon cas se situa entre els anys 2017 i 2023, quan la policia de Detroit, als Estats Units, emprava un sistema de reconeixement facial mitjançant IA per capturar delinqüents. En un d'aquests casos, Robert Williams va ser injustament detingut perquè el sistema va relacionar la seva fotografia del carnet de conduir amb un vídeo de seguretat d'una botiga el 2018. En denunciar aquest arrest injust, la ciutat va haver de pagar 300.000 dòlars a la víctima, a més de reavaluar si les detencions dels anys anteriors s'havien fet correctament (The Guardian, 2024).

Aleshores, qui en té la responsabilitat? Algunes podrien assenyalar la programadora, altres les dades, i d'altres la societat... En molts d'aquests casos, la responsabilitat recau en les dades, que són un reflex de la societat. En el cas d'Amazon, les dades van ser extreptes dels currículums de les treballadores dels últims deu anys, on la majoria eren homes. Per tant, l'algorisme va interpretar que aquesta era l'única possibilitat viable. De la mateixa manera, si el detector facial estava majoritàriament entrenat amb cares amb característiques caucàsiques, possiblement no estava prou desenvolupat per detectar faccions

afroamericanes, sense tenir en compte els prejudicis existents respecte a la població afroamericana i la criminalitat.

Utilitzar eines d'intel·ligència artificial per no quedar-se enrere tecnològicament i optimitzar l'eficiència dels processos és molt important, però s'ha de fer d'una manera que no discrimini cap col·lectiu, per tal d'evitar judicis injustos.

3. Antecedents

Nombrosos treballs i estudis s'han dut a terme en els darrers anys centrant-se en l'anàlisi de dades relacionades amb l'àmbit cinematogràfic, especialment posant èmfasi en les crítiques i comentaris que les usuàries publiquen en línia sobre pel·lícules i sèries (Dashtipour, Gogate, Adeel, Larajini & Hussain, 2021; Kumar, Harish & Darshan, 2019; Frangidis, Georgiou & Papadopoulos, 2020). Aquestes dades, recollides sovint a través de plataformes especialitzades com IMDb, Rotten Tomatoes o Letterboxd, constitueixen una font rica d'informació que permet comprendre en profunditat les opinions, preferències i expectatives del públic. A més d'ajudar a mesurar l'impacte i l'èxit potencial d'una obra audiovisual, aquesta informació pot influir de manera directa en decisions estratègiques com ara la planificació del màrqueting, l'ajust del pressupost o la redefinició de continguts.

Per exemple, quan una pel·lícula rep crítiques majoritàriament positives abans del seu llançament oficial —sovint gràcies a passis anticipats o festivals de cinema—, les productores poden aprofitar aquest impuls per intensificar les campanyes publicitàries, destacant els aspectes més valorats i fomentant el boca-orella digital. En canvi, si les reaccions inicials són negatives, és habitual que es revisin les estratègies de promoció, es reconsiderin les dates d'estrena o, en casos extrems, es proposin modificacions en el muntatge o el to narratiu per millorar la recepció crítica i comercial.

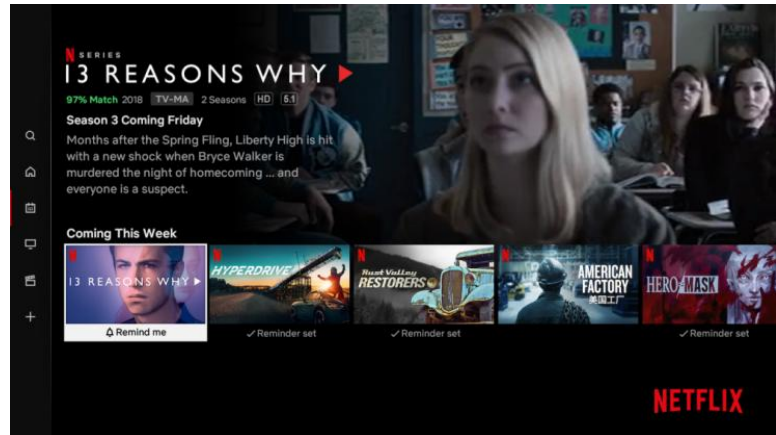
Més enllà de l'anàlisi quantitativa (com puntuacions o nombre de crítiques), el desenvolupament de tècniques d'intel·ligència artificial ha obert la porta a una lectura qualitativa i emocional molt més sofisticada. En aquest sentit, l'aplicació de models d'aprenentatge profund, com els Transformers (per exemple, BERT de Google o GPT desenvolupat per OpenAI), permet fer anàlisi de sentiments avançats sobre textos lliures escrits per les usuàries. Aquests models no només determinen si una crítica és positiva o negativa, sinó que també poden identificar elements concrets que han generat emocions, com la qualitat de la fotografia, la força del guió, el ritme narratiu o la interpretació dels actors.

Aquesta capacitat d'extracció semàntica i emocional resulta especialment útil per a estudis de mercat, desenvolupadors de guions i plataformes de streaming que busquen adaptar el seu contingut a les sensibilitats i preferències d'audiències específiques. De fet, algunes empreses comencen a incorporar recomanadors intel·ligents que, a partir de les emocions detectades en les opinions de les usuàries o

en el seu historial de visualització, poden suggerir continguts alineats amb el seu estat emocional o preferències narratives.

Un dels referents pel que fa a plataformes de *streaming* o vídeo a la carta (*Video on Demand*, VoD) és el cas de Netflix, fundada l'any 1997, però que s'ha fet sentir arreu del món durant l'última dècada gràcies a la seva selecció de pel·lícules i a les seves pròpies produccions.

Una de les claus perquè sigui una de les plataformes més populars és el seu algorisme de recomanació, dissenyat perquè la usuària no vulgui deixar de consumir contingut. Com que és un dels factors clau del seu èxit, no sorprèn que no es faci públic en detall com funciona exactament aquest sistema, a més que els algorismes d'aprenentatge automàtic són altament sofisticats. Així i tot, si es fa una cerca acurada, es pot trobar informació rellevant sobre el seu funcionament.



Il·lustració 1. Interfície de Netflix. Font: Netflix

Segons el centre d'ajuda de Netflix, la plataforma genera recomanacions a partir del càlcul de la probabilitat que gaudeixis d'un títol concret, basant-se en:

- L'historial de visualitzacions i la puntuació que has assignat a altres continguts.
- Les preferències d'altres usuàries amb gustos similars als teus.
- La informació descriptiva dels títols, com el gènere, les categories, els actors, la data d'estrena, etc.

A més, per afinar encara més la personalització, també es tenen en compte:

- L'hora del dia en què consumeixes contingut.
- Els idiomes que prefereixes.
- Els dispositius des d'on accedeixes a la plataforma.
- El temps que passes mirant cada títol.

Es tracta d'un algorisme altament complex i en constant actualització, que també té en compte l'estat en què et trobes respecte a un contingut concret: si acabes de veure una sèrie, si encara la tens a mitges o si només n'has començat un episodi. Aquestes variacions fan que cada usuària rebi una pantalla d'inici diferent, adaptada als seus hàbits i preferències.

En el següent apartat, s'analitza amb més detall el cas concret d'una altra plataforma: Filmin, com a exemple de sistema de recomanació alternatiu que, tot i no incorporar IA, ofereix una visió complementària que permet entendre millor els avantatges i limitacions dels diferents enfocaments actuals.

3.1. Entrevista amb l'equip de Filmin

Al context actual dels sistemes de recomanació aplicats a les plataformes de *streaming*, ens adonem que existeixen diversos punts de vista segons el tipus de contingut, la identitat de la plataforma i els recursos tecnològics disponibles. Un exemple representatiu a l'àmbit espanyol és Filmin, una de les plataformes més populars del sector, especialitzat en cinema d'autor i independent que opta per un model híbrid, però no automatitzat mitjançant intel·ligència artificial.

Segons l'entrevista realitzada a representants de la plataforma (Annex 1), el sistema de recomanació es basa en la combinació de dos pilars principals:

- Curació editorial manual: creació de col·leccions temàtiques seleccionades per un equip especialitzat, que proposa continguts segons criteris culturals i d'interès cinematogràfic.
- Model de personalització bàsica on es té en compte principalment:
 - o L'historial de visualització de cada usuària.
 - o Les valoracions que es fan dels films.

Tot i això, aquest sistema de recomanació és menys sofisticat i automatitzat que el d'altres plataformes, ja que dona més pes a la selecció editorial que a l'automatització basada en algoritmes complexos. Aquest enfocament permet a la plataforma mantenir una gran coherència editorial, ajustada a la seva identitat cultural, però limita greument el grau de personalització i automatització que sí que poden oferir altres plataformes de la competència, que són més tecnificades.

Un dels aspectes més rellevants de l'entrevista és la manca actual de tècniques d'aprenentatge automàtic o intel·ligència artificial en el procés de recomanació. Encara que l'equip de Filmin reconeix la importància d'avançar cap a recomanacions més ajustades a les preferències emocionals de la usuària, les formes d'abordar aquesta problemàtica se suporten en enquestes simples i manuals, preguntant directament com se sent la persona, sense implementar cap mena d'anàlisi de sentiments a partir de dades no estructurades com el llenguatge natural. Aquesta decisió respon, en part, al seu desig com empresa de conservar un control editorial sobre cada usuària, garantint una oferta cultural diversa i alineada amb els valors de la plataforma. Tot i això, també exposa algunes limitacions tècniques que poden afectar a l'escalabilitat del sistema i a la capacitat d'adaptació en períodes curts o fins i tot en temps real.

A més, l'equip identifica diversos reptes comuns amb els sistemes de recomanació ja esmentats amb anterioritat, com la problemàtica del Cold Start, la dificultat de mantenir actualitzades els suggeriments a causa dels canvis constants en els drets de distribució i l'equilibri entre oferir contingut similar al ja consumit i facilitar el descobriment de noves propostes.

Pel que fa al disseny de l'experiència d'usuària (UX), ens han comentat que li dona gran importància a la interfície com a mitjà de mediació entre les recomanacions i la usuària final. Es valora especialment la presentació visual de les col·leccions temàtiques, la integració de la sinopsi, puntuacions i altres metadades rellevants per donar suport a la presa de decisions de la persona usuària. D'aquesta forma, es recullen dades qualitatives a través de les valoracions, atenció al client i xarxes socials, la qual cosa permet una millora continua del sistema, tot i no comptar amb una eina automatitzada per processar aquesta retroalimentació.

3.2. Limitacions i oportunitats del model de recomanació de Filmin

Aquest enfocament manual, tot i ser coherent amb la seva proposta cultural i d'imatge de marca, presenta una clara oportunitat per desenvolupar noves alternatives tecnològiques. Si més no, el sistema de recomanació dissenyat en aquest treball de final de grau proposa una alternativa a un model com el de Filmin, incorporant eines d'intel·ligència artificial per interpretar llenguatge natural de les persones i extraure informació valuosa mitjançant l'anàlisi de sentiments. Aquest model, a diferència del de Filmin, que únicament es basa en l'historial de visites i puntuacions, incorpora també indicadors emocionals, cosa que permet oferir una experiència d'usuària més significativa i contextual.

Aquest treball no pretén oposar-se a l'enfocament de Filmin, sinó complementar-lo des d'una perspectiva més tecnològica, explorant les possibilitats que ofereixen els models d'aprenentatge automàtic perquè les interaccions eina-persona sigui més profitosa i gratificant. També s'aborden des d'un punt de vista crític, els riscos que porten la implementació de models automatitzats, com els biaixos algorítmics, la pèrdua de diversitat en tots els sentits, que l'equip de Filmin ha pogut solucionar amb èxit gràcies a la intervenció humana des del primer moment. D'aquesta forma, la proposta presentada en aquest treball pretén el millor de cada una de les parts: l'eficiència que podem trobar a l'aprenentatge automàtic o intel·ligència artificial i la curació ètica pròpia del criteri humà.

En definitiva, els treballs previs i el cas de Filmin han estat clau per delimitar els objectius i les limitacions del sistema desenvolupat, cosa que permet orientar-lo cap a una proposta innovadora, centrada en la comprensió emocional del llenguatge com a eina de recomanació cinematogràfica.

A partir d'aquestes reflexions, aquest treball planteja el desenvolupament d'un sistema de recomanació alternatiu que complementi les propostes actuals amb un enfocament més emocional i personalitzat. L'objectiu és oferir recomanacions audiovisuals a partir de l'estat emocional de la usuària, interpretat mitjançant un model d'anàlisi de sentiments aplicat a un text lliure. Aquesta aproximació permet generar resultats més contextualitzats i rellevants, aportant una nova capa de significat que va més enllà de l'historial de visualització o de les valoracions prèvies.

4. Metodologia

Aquest capítol descriu el procés de disseny, implementació i validació d'una eina de recomanació cinematogràfica basada en l'anàlisi emocional del llenguatge natural. El desenvolupament ha seguit una seqüència estructurada de fases. En primer lloc, es van seleccionar i configurar les eines tècniques necessàries per desenvolupar el sistema, incloent-hi l'ús d'una API per a l'anàlisi de sentiments. A continuació, es va procedir a la recollida i preparació de les dades, tant pel que fa als inputs textuais com a la base de dades cinematogràfica externa. Un cop recollides les dades, es va dur a terme la maquetació de la interfície de l'eina, pensada per facilitar la interacció de la usuària i la comprensió del resultat recomanat. Finalment, es va plantejar una fase de test amb participants reals per avaluar la funcionalitat, la qualitat de les recomanacions i la relació entre emocions expressades i resultats obtinguts. Aquest procés metodològic es detalla a continuació, pas a pas, i es complementa amb el codi complet recollit a l'Annex 2.

4.1. Eines utilitzades

Per dur a terme la demostració del meu sistema de recomanació de pel·lícules basat en els sentiments, vaig usar diverses eines. Per a la programació web, vaig treballar amb Visual Studio Code, una aplicació desenvolupada per Microsoft àmpliament reconeguda i compatible amb Windows, macOS, Linux, i també disponible en versió web.

Pel que fa als llenguatges de programació i maquetació, vaig fer servir JavaScript, HTML i CSS, tecnologies fonamentals en el desenvolupament web. JavaScript em va permetre gestionar la lògica del sistema, HTML va estructurar les pàgines i CSS va aportar estil i personalitat a la interfície.

4.1.1. API usada

Una Interfície de Programació d'Aplicacions (API, per les seves sigles en anglès: Application Programming Interface) és un conjunt de protocols i eines que faciliten el desenvolupament d'aplicacions de programari, definint les operacions, entrades, sortides i tipus subjacents d'un component. Les API permeten separar la funcionalitat de la seva implementació, fet que facilita l'evolució dels sistemes sense afectar la interfície (Clark, 2020).

Essencialment, una API actua com una passarel·la a través de la qual una aplicació pot sol·licitar serveis a biblioteques o sistemes operatius, definint el vocabulari i les convencions necessàries per accedir-hi (Tollerud, 2016).

En aquest projecte, he utilitzat una API web. A diferència de les API estàndard, les API web funcionen a través de mètodes HTTP com *GET*, *POST*, *PUT* o *DELETE*, per comunicar-se amb serveis en línia. Cada un dels mètodes vol dir el següent:

- *GET*. S'usa per obtenir dades d'un servidor. No modifica les dades, únicament les consulta.
- *POST*. Es fa servir per enviar dades al servidor i crear un nou recurs com podria ser afegir una nova pel·lícula a la base de dades.
- *PUT*. S'emptra per actualitzar completament un recurs ja existent al servidor.
- *DELETE*. Com el seu nom indica en anglès, per eliminar un recurs del servidor.

Aquest tipus d'API requereix connexió a internet, però permet accedir als serveis des de diferents dispositius i plataformes de manera simultània (Lakshmiraghavan, 2013).

The Movie Database API (TMDB), encarregada de proporcionar tota la informació necessària sobre les pel·lícules i retornar a la usuària el contingut sol·licitat mitjançant consultes a la seva base de dades. És àmpliament utilitzada per desenvolupadors d'aplicacions i analistes de dades.

El seu funcionament consisteix a obtenir una clau d'accés (API key) en registrar-se a TMDB, la qual permet accedir a les dades a través de peticions HTTP. Els resultats varien segons la petició realitzada:

- Cerca de pel·lícules i sèries: permet obtenir informació detallada sobre títols concrets, incloent-hi sinopsi, puntuacions, gènere, actors, directors i més.
- Tendències i títols més populars: ofereix llistats de pel·lícules i sèries populars en un moment determinat.
- Detalls de persones: proporciona informació sobre actors, directors i altres professionals de la indústria cinematogràfica.
- Tràilers i imatges: permet obtenir vídeos promocionals, pòsters i altres imatges relacionades amb una producció.

4.1.2. Intel·ligència artificial

Com ja s'ha esmentat en el marc teòric, l'aprenentatge profund (*deep learning*) i la intel·ligència artificial tenen un paper fonamental en aquest projecte. Un dels components clau és "Emotion English DistilRoBERTa-base", una eina basada en *Transformers* capaç de detectar emocions en textos en llengua anglesa mitjançant tècniques d'intel·ligència artificial. Aquest model distingeix entre les sis emocions bàsiques definides per Paul Ekman i una emoció addicional, la neutralitat:

- | | |
|------------|-------------|
| 1. Ira | 5. Tristesa |
| 2. Fàstic | 6. Sorpresa |
| 3. Por | 7. Neutral |
| 4. Alegria | |

Aquest model es va entrenar a partir de cinc fonts diferents:

- BookCorpus, un conjunt de dades d'11.038 llibres que no estan publicats.
- English Wikipedia, tot el text excloent llistes, taules i títols.
- CC-News, un conjunt de dades amb 63 milions d'articles entre setembre de 2016 i 2019.
- OpenWebText, una recreació de codi obert de WebText, el conjunt de dades usat per entrenar GPT-2.
- Stories: una petita secció de dades procedent de CommonCrawl, filtrada per incloure històries curtes similars als esquemes de Winograd.

Els *Winograd schemas* són frases dissenyades per posar a prova la comprensió semàntica i el raonament de models d'intel·ligència artificial. Un exemple seria:

"The trophy doesn't fit in the brown suitcase because it is too small."

Què és "*too small*"? Al trofeu o a la maleta?

Aquest tipus de frase requereix un raonament contextual que les màquines troben especialment difícil.

En les proves d'avaluació, aquest model va obtenir una precisió del 66%, superant significativament la línia base de l'atzar (14%) en una classificació de set categories.

4.2. Obtenció de les dades

El primer pas per desenvolupar l'eina de recomanació ha estat determinar com obtenir les dades necessàries per generar suggeriments cinematogràfics personalitzats. Inicialment, es va considerar la possibilitat de dur a terme *web scraping*, una tècnica que permet extreure i emmagatzemar informació de pàgines web —com ara textos o imatges— en formats estructurats com ara arxius .csv. Per tal d'identificar les fonts de dades més adients, es va fer una anàlisi comparativa de les principals plataformes de streaming disponibles, amb l'objectiu d'avaluar la disponibilitat i accessibilitat pública dels seus catàlegs, així com el volum de continguts oferts.

Plataforma	Nombre de títols	Llista pública
Netflix	5.720	No
Amazon Prime Video	5.354	No
Disney+	2.461	No
HBO Max	2.300	No
Apple TV+	226	No
Filmin	12.400+	Sí
Rakuten TV	2.500	Parcialment ¹

Taula 2. Nombre de títols disponibles per plataforma. Elaboració pròpia.

La plataforma que més em va cridar l'atenció va ser Filmin, l'empresa espanyola que compta amb més de 12.400 pel·lícules i sèries, molt per sobre de la seva competència. A més, és l'única plataforma on qualsevol persona usuària pot consultar la llista completa de títols que ofereix. En el cas de les plataformes internacionals que apareixen a les primeres posicions de la taula, també és possible consultar el llistat, però a través d'un tercer: JustWatch. Tanmateix, com que això implica confiar en una font externa, vaig considerar més segur i fiable utilitzar les dades que sé del cert que són proporcionades per l'empresa espanyola. Un cop decidit d'on volia obtenir les dades, calia veure com volia fer-ho. Inicialment, vaig contemplar fer *web scraping* amb l'extensió de navegador Instant Data Scraper, una eina especialitzada en aquesta tasca. Però indagant una mica més en el seu funcionament,


¹ A la plataforma Rakuten TV, té un catàleg mixt amb contingut gratuït amb anuncis, subscripció i compra de pel·lícules i sèries. Per això, sense un compte, només es mostraria el contingut gratuït, limitant la disponibilitat d'una llista pública completa.

em vaig adonar que no em permetria obtenir totes les dades que necessitava. Aquesta eina funciona emmagatzemant tots els textos que apareixen a la pàgina web en el moment que se li indica. A la pàgina principal de Filmin només apareixien els textos del títol, la direcció i la puntuació del film. Tanmateix, jo volia obtenir les dades següents per a cada pel·lícula o sèrie:

- Títol
- Direcció
- Data d'estrena
- Gènere o gèneres
- Sinopsi
- Temes

Com que aquestes dades només estaven disponibles accedint a cadascun dels enllaços individuals dels films, i no visibles directament a la pàgina principal, vaig descartar aquesta opció ràpidament.

L'altra alternativa era la més intuïtiva, però també la més complexa: fer-ho jo mateix. Això implicava escriure un codi en un llenguatge de programació com




Il·lustració 2. Interfície de Filmin. Font: Filmin

Python o R —en el meu cas, Python—, habituals en la manipulació de dades. Però en començar a fer-ho, em vaig adonar que els meus coneixements de Python no eren tan avançats com calia per dur a terme aquest tipus de *web scraping*, cosa que em va desanimar força. Necessitava una alternativa ràpida si volia continuar amb el projecte i obtenir dades sobre sèries i pel·lícules. Ho vaig haver de replantejar tot des de zero.

Amb l'opció de Filmin descartada, va entrar en joc l'API de The Movie Database, que proporciona moltes de les dades que buscava, tot i que no em permet obtenir un dels elements de la llista anterior: els temes.

4.3. Programació

Un cop la font de dades ha estat definida, calia plantejar com s'estructuraria l'eina internament per al bon funcionament d'aquesta.



Il·lustració 3. Diagrama dels processos del prototip. Elaboració pròpia.

En primer lloc, cal plantejar-se com serà la interacció de la persona usuària amb l'eina, i per això s'han de definir els punts següents:

- Quina pregunta volem fer a la persona usuària?
- Com serà la forma en què ens respondrà aquesta pregunta?

Per respondre la primera qüestió, és evident que la manera com preguntem alguna cosa a algú influirà molt en la seva resposta. En primera instància, la pregunta que vaig plantejar va ser un bàsic “*Com et sents?*”, perquè la usuària pogués respondre lliurement.

Pel que fa a la segona pregunta, no sabria dir amb precisió quina és la forma més bona perquè la usuària respongui, però sí que dispo de diverses opcions que podrien ser efectives.

En primer lloc, com que soc una persona que passa bastant de temps davant de l'ordinador, em va semblar que crear un espai de text on cada persona pogués escriure com se sent lliurement era l'opció més adequada. Amb la pregunta formulada i aquest tipus de resposta, gràcies a l'eina *DistilRoBERTa-base*, podem interpretar exactament què està experimentant aquella usuària, sigui una emoció positiva, negativa o qualsevol altra que l'eina sigui capaç d'identificar.

En segon lloc, vaig considerar com seria si, en comptes d'un espai de text on la usuària o usuària escrivís com se sent, se simplifiqués el procés a prémer un botó que representés l'emoció del moment. Amb aquesta opció, l'eina de *machine learning* passaria a un segon pla, però perdríem aquella informació addicional que només el text ens pot proporcionar. Aquesta alternativa podria ser més viable en general. Tot i que escriure en un ordinador no suposa gaire problema, fer-ho en un dispositiu mòbil ja pot resultar més incòmode; en una tauleta, encara més, i després d'una petita conversa amb els meus pares, vaig adonar-me que implementar-ho a una televisió seria una molt mala idea: “*A ningú li agrada escriure a la tele*”, em van dir.

Amb aquesta segona opció, guanyariem en simplicitat i evitariem que la usuària o usuària vulgui sortir de l'aplicació immediatament, tot i perdre una mica d'informació textual. En qualsevol cas, caldria valorar si mantenir el text en plataformes com l'ordinador podria funcionar millor.

Aquest aspecte es desenvoluparà amb més detall en l'apartat següent. A continuació s'explicarà el funcionament del codi al detall:

El codi, en primer lloc, es declaren les dependències, que en aquest cas són *React* i *cosineSimilarity*, on la primera és l'encarregada de guardar i actualitzar les dades com poden ser les emocions, films, usuàries... executar els processos, crear l'UI, l'interfície d'usuària i reaccionar a les accions que fa la usuària a més d'actualitzar aquesta interfície i la segona compara les pel·lícules marcades com vistes amb les noves recomanacions usant vectors de gènere.

Les claus d'accés de l'API i del mòdul d'anàlisi de sentiments són declarades, aconseguint-la al lloc web corresponent. Aquestes claus d'accés permeten verificar d'una forma segura que l'eina en qüestió

és utilitzada d'una forma segura i controlada, sense que altres usuàries siguin capaços d'accedir a les dades que jo genero i uso.

4.3.1. Funcionament tècnic de l'eina

L'eina està desenvolupada amb una estructura modular de React, una llibreria de JavaScript per desenvolupar interfícies d'usuària. Aquesta permet gestionar l'estat de l'aplicació i reaccionar de manera dinàmica a les accions de la usuària, especialment per introduir emocions i visualitzar recomanacions.

El component principal de l'aplicació s'encarrega de controlar l'estat global mitjançant *useState*, que emmagatzema variables com l'entrada emocional de la usuària, els resultats de l'anàlisi de sentiment, les pel·lícules recomanades i l'estat de càrrega. Això permet que, quan es detecta una nova emoció o se sol·licita una nova recomanació, tota la interfície es torni a carregar automàticament per mostrar la nova informació.

També s'usa *useEffect* per executar accions secundàries, com per exemple la crida a l'API de TheMovieDataBase un cop es detecta l'emoció.

L'espai perquè la persona usuària pugui escriure com se sent és a un espai de text. Aquesta entrada s'envia al model d'aprenentatge automàtic DistilRoBERTa-base, que analitza el contingut i retorna una de les set emocions que és capaç d'analitzar. Com ja s'ha esmentat amb anterioritat, aquest model ha estat entrenat amb textos en llengua anglesa, és a dir, textos en català, castellà o qualsevol llengua que no sigui l'anglesa no serà capaç d'interpretar-la, després de diversos intents de superar aquesta limitació, present a la documentació de l'API, vaig arribar a la conclusió de, provisionalment, fer ús d'aquesta llengua. Poder aconseguir que el model retorni una de les set emocions és essencial per poder continuar amb la següent fase del procés: associar les emocions amb gèneres.

Primer de tot, es defineixen els gèneres que s'associaran amb cada sentiment que el mòdul d'aprenentatge automàtic és capaç d'analitzar i interpretar usant l'identificador que s'emptra a The Movie Database (TMDB), quedant les següents relacions:

	Acció	Animació	Aventura	Ciència-Ficció	Comèdia	Crim	Drama	Família	Fantasia	Misteri	Música	Romanç	Suspens	Terror
<i>Anger</i>	X					X				X			X	
<i>Disgust</i>			X			X							X	
<i>Fear</i>						X				X			X	X
<i>Joy</i>			X		X			X	X		X			
<i>Sadness</i>							X					X		
<i>Surprise</i>	X	X	X	X					X	X				

Taula 3. Gèneres seleccionats per emoció. Elaboració pròpia.

Cada emoció identificada es relaciona amb el conjunt de gèneres de pel·lícules. Aquesta relació està codificada mitjançant un diccionari on cada emoció es vincula amb els identificadors que TMDb usa per cada un dels gèneres. Això permet generar directament els gèneres de films de la crida que es farà a l'API de TMDb. El següent pas és fer la crida a TMDb usant els gèneres associats amb l'emoció detectada. Aquesta crida retorna una llista de pel·lícules que són guardades a l'estat de l'aplicació. Durant aquest procés, es gestionen la possibilitat d'errors de resposta, paginació i possibles absències de resultats.

L'eina inclou un mòdul addicional de comparació de similitud per afinar les recomanacions. Aquest mòdul es basa en la funció cosineSimilarity, que compara les pel·lícules recomanades amb les pel·lícules que la usuària ha marcat com a vistes.

Cada pel·lícula és representada com un vector binari on cada posició representa un gènere (1 si hi és, 0 si no), i es calcula la similitud angular entre vectors. Aquest procés permet filtrar i ordenar les recomanacions en funció de la seva proximitat temàtica respecte als gustos previs de la usuària. Un cop seleccionats els films més rellevants, aquestes es mostren a la usuària mitjançant targetes visuals a la interfície afegint informació com:

Emotion Driven Movie Recommender

1

Recommend Movies

Movies Viewed

Watched Movies

- Cinema Paradiso (1988)
- Pursuit of a Killer (1985)
- Travels of Hibari and Chiemi (1962)
- (500) Days of Summer (2009)
- Anora (2024)
- Titanic (1997)
- Pride & Prejudice (2005)
- Trolls World Tour (2020)
- Snow White and the Seven Dwarfs (1938)

Il·lustració 4. Llista de pel·lícules vistes per la usuària
Elaboració pròpia

- 2- Títol
- 3- Gèneres
- 4- Sinòpsi
- 5- Puntuació

Es fa servir una estructura visual clara per afavorir la navegació i la decisió. Quan es canvia l'entrada emocional, les recomanacions es tornen a generar automàticament.

Emotion Driven Movie Recommender

Recommend Movies
Movies Viewed

Search Movies

Generate New Movies

Poster	Title	Genres	Overview	Rating	Action
	Snow White and the Seven Dwarfs (1938)	Fantasy, Animation, Family	A beautiful girl, Snow White, takes refuge in the forest in the house of seven dwarfs to hide from her stepmother, the wicked Queen. The Queen is jealous because she wants to be known as "the fairest in the land," and Snow White's beauty surpasses her own.	7.123 / 10	Mark as Watched
	Monsters, Inc. (2001)	Animation, Comedy, Family	Lovable Sulley and his wisecracking sidekick Mike Wazowski are the top scare team at Monsters, Inc., the scream-processing factory in Monstropolis. When a little girl named Boo wanders into their world, it's the monsters who are scared silly, and it's up to Sulley and Mike to keep her out of sight and get her back home.	7.844 / 10	Mark as Watched

Il·lustració 5. Interfície general del prototip. Elaboració pròpia

Quant a seguretat i privadesa, les claus de les API es gestionen de forma segura, però React és una eina *client-side*, és a dir, tot passa al navegador de la persona i, per tant, si es volgués usar d'una forma més professional, caldria traslladar les operacions del navegador a un *backend* amb bases de dades, per protegir millor les dades i evitar l'exposició d'aquestes. Aquest prototip és dissenyat per fer demostracions individuals.

4.4. Limitacions de l'algorisme

Tot i el sistema poder resoldre amb èxit la seva funció bàsica: poder proporcionar suggeriments cinematogràfics a partir d'emocions detectades, cal esmentar una sèrie de limitacions tècniques i conceptuals que poden condicionar l'experiència de la usuària i afectar a l'escalabilitat d'aquesta.

- Dependència d'una única entrada textual. La interacció es basa exclusivament en el text lliure introduït per la usuària, fet que pot resultar poc pràctic en dispositius com televisors o tauletes.
- Classificació emocional simplificada. El model d'anàlisi de sentiments només detecta emocions bàsiques, sense captar matisos més subtils o complexos.
- Assignació fixa entre emocions i gèneres. La relació entre emocions i gèneres cinematogràfics s'ha definit manualment, sense tenir en compte preferències individuals ni variacions culturals.
- Absència de personalització contínua. El sistema no guarda cap historial d'usuària, per tant, no aprèn ni ajusta les recomanacions al llarg del temps.
- Recomanació basada únicament en gèneres. La selecció de pel·lícules es fa segons coincidències de gènere, sense considerar altres característiques com narrativa, estil visual, ritme o valoracions.
- Exposició potencial de claus i dades. En ser una aplicació client-side (React), les claus de l'API poden quedar exposades si no es trasllada la lògica crítica a un servidor segur.

Algunes d'aquestes limitacions serien relativament senzilles de resoldre en versions més avançades del prototip. Per exemple, la dependència d'una única entrada textual es podria solucionar amb la integració d'eines de reconeixement de veu, especialment útils en dispositius com televisors o tauletes. De la mateixa manera, la seguretat de les claus d'accés es podria garantir traslladant la lògica crítica a un servidor *backend*, evitant així l'exposició directa al navegador.

Altres qüestions, però, plantegen reptes més complexos. La classificació emocional simplificada requereix entrenar models més avançats de processament del llenguatge natural, capaços de captar matisos emocionals i ironies, la qual cosa implica més dades, més potència computacional i una fase d'entrenament més elaborada. També és significativament més difícil substituir l'assignació fixa entre emocions i gèneres per un sistema dinàmic basat en preferències personals i context cultural, ja que això implicaria recollir i processar grans volums de dades d'usuària, amb les corresponents implicacions ètiques i tècniques.

Finalment, la manca de personalització contínua i la dependència exclusiva del gènere com a criteri de recomanació són limitacions estructurals que requeririen redissenyar l'arquitectura del sistema. Caldria implementar un mòdul d'aprenentatge automàtic que emmagatzemi i analitzi l'activitat de cada usuària al llarg del temps, incorporant factors com la narrativa, el ritme o les valoracions, cosa que augmentaria considerablement la complexitat del projecte.

5. Pla d'exploració

Després d'haver tractat, des d'un punt de vista teòric i pràctic, tot allò que envolta aquest treball, l'objectiu d'aquest capítol és definir com es podria implementar, escalar i comercialitzar l'eina desenvolupada: un prototip de recomanació de pel·lícules basat en emocions mitjançant intel·ligència artificial.

5.1. Validació i testatge amb expertes

Abans de plantejar-ne l'escalabilitat o comercialització, és fonamental avaluar la qualitat de les recomanacions i la usabilitat del sistema mitjançant un testatge rigorós. Tot i que limitacions de temps han impedit la seva execució real, el disseny d'aquesta validació es va planificar amb els següents elements:

Objectiu

L'experiment buscava avaluar:

1. Precisió de les recomanacions: Si les pel·lícules suggerides s'ajustaven a l'estat d'ànim indicat per la usuària, tenint en compte factors com originalitat, coherència temàtica i profunditat del missatge.
2. Experiència d'usuària: Usabilitat de la interfície (intuïtiva, clara, estèticament atractiva) i preferència entre dos models de resposta:
 - Versió A: Entrada de text lliure per descriure l'estat emocional.
 - Versió B: Selecció mitjançant botons predissenyats (ex.: "Alegre", "Confús", "Trist").

Metodologia

S'haurien reclutat 5–10 participants amb perfils d'expertesa cinematogràfica (crítics, acadèmics o cinèfils actius en comunitats especialitzades), seguint criteris com:

- Coneixement ampli de cinema (gèneres, èpoques, cultures).
- Habilitat per a l'anàlisi qualitativa i argumentada.

El procediment incloïa:

1. Consentiment informat: Explicació dels objectius i recollida de dades.
2. Test A/B: Cada participant provava una de les dues versions del sistema, amb tasques concretes:
 - Seleccionar o descriure el seu estat d'ànim.
 - Rebre i valorar 3–5 recomanacions (rellevància, originalitat).
 - Avaluar la interfície en usabilitat i disseny.
3. Qüestionari qualitatiu: Opinió obertes sobre fortaleces, debilitats i suggeriments. Opcionalment, alguns participants podrien provar les dues versions per comparar-les directament.

Anàlisi prevista

Les dades qualitatives s'haurien analitzat per identificar:

- Patrons comuns: Quina versió generava recomanacions més acurades o era més fàcil d'usar.
- Oportunitats de millora: Ex.: ajustos en el model d'anàlisi de sentiments, redisseny de la interfície, o integració d'un sistema híbrid (text + botons).

Aquesta validació hauria estat clau per validar la hipòtesi inicial (la relació entre estat emocional i recomanació efectiva) i justificar inversions futures en escalabilitat. Els resultats també haurien orientat decisions com:

- Simplificar la interacció (prioritzant botons si els experts trobaven el text lliure massa complex).
- Millorar la base de dades afegint metadades emocionals més precises (ex.: etiquetes de "tònic narratiu" o "arquetip emocional" a cada pel·lícula).

El testatge amb les expertes i cinèfiles seria sense dubte el primer pas a realitzar per a la bona explotació de l'eina de recomanació cinematogràfica. Obtenir una validació per part d'expertes és primordial per saber que el projecte està seguint una bona trajectòria, havent de fer canvis o girs en la direcció creativa o tècnica d'aquest.

5.2. Proposta de valor

L'eina desenvolupada permet generar recomanacions de contingut audiovisual a partir d'un input emocional: en format de línia de text o selecció d'emocions, mitjançant un model d'anàlisi de sentiments i una base de dades externa. A diferència dels motors de recomanació tradicionals, que es basen en comportaments previs o popularitat, aquest sistema ofereix una experiència personalitzada i emocionalment adaptativa. Això pot ser especialment valuós per a plataformes que busquen millorar la connexió emocional amb la seva audiència.

5.3. Públic objectiu


El model de negoci plantejat és de tipus B2B (business-to-business), en què s'oferiria el producte a plataformes de vídeo a la carta (VoD) que vulguin incorporar un sistema de recomanació emocional com a valor afegit. Aquest públic inclouria tant plataformes grans i consolidades, com Netflix, Amazon Prime Video o HBO Max, com d'altres més especialitzades, com Filmin o Mubi. L'eina es podria integrar per complementar els sistemes de recomanació ja existents en les aplicacions de les diverses plataformes: mòbil, navegador, televisor, tauleta, etc. També es podria dirigir a plataformes de nínxol que vulguin oferir experiències més immersives o emocionalment adaptatives.

5.4. Anàlisi de mercat

El mercat de vídeo a la carta no para de créixer, tant en volum de contingut com en nombre de subscriptors, pujant un 780% en usuaris actius a la plataforma Netflix des de 2013, dos anys abans que aparegués a Espanya fins l'últim trimestre de 2024. Aquesta saturació fa que la capacitat de recomanar contingut rellevant sigui un dels principals factors diferencials entre plataformes.

Les tendències actuals apunten cap a una demanda creixent de personalització basada en dades emocionals, com ara Spotify Wrapped, Moodplay o les propostes de TikTok.

Per això, el producte no s'orientaria a totes les plataformes indiscriminadament, sinó a aquelles que busquen una diferenciació per la via de l'experiència emocional o que ja tenen sistemes de recomanació propis, però els volen complementar.



Il·lustració 6. Evolució trimestral del nombre de subscriptors de Netflix arreu del món (2013–2024). Font: Statista

5.5. Anàlisi de la competència

Actualment, la majoria de les plataformes grans utilitzen sistemes de recomanació propis, sovint propietaris i basats en algorismes interns (com Netflix, que no externalitza cap component del seu sistema). No obstant això, hi ha empreses terceres que ofereixen recomanacions com a servei, com ara:

- Movio: segmentació emocional i demogràfica, però enfocada a sales de cinema.
- Cinelytic: ús d'intel·ligència artificial per predir rendiment de pel·lícules.
- Jinni (antic): projecte pioner en recomanacions emocionals, però discontinuat.

Cap d'aquestes solucions no ofereix exactament el mateix servei que la proposta d'aquest treball: una eina *plug-and-play* de recomanació emocional adaptable a qualsevol entorn de vídeo a la carta, especialment útil per a plataformes que no poden invertir en un sistema propietari.

5.6. Model de negoci

Es planteja comercialitzar el producte com un *Software Development Kit* (SDK), que permet als proveïdors de serveis dissenyar, provar i avaluar els serveis abans de publicar-los, i actualitzar-los durant la seva vida útil, en un cicle continu entre el desenvolupament i les operacions conegudes com a DevOps (Rossem, Tavernier, Colle, Pickavet & Demeester, 2018), amb integració local, cosa que ofereix flexibilitat i independència al client final.

Models de monetització possibles:

- Llicència mensual o anual.
- Tarifació segons nombre d'usuàries actives.
- Suport tècnic i manteniment com a serveis addicionals.

Aquest format evita la necessitat de connexió constant a servidors externs (com passaria amb una API), i permet una millor escalabilitat i seguretat.

5.7. Estratègia de comunicació i comercialització

Inicialment, es proposa una estratègia de llançament directe a plataformes petites o mitjanes, amb l'objectiu de validar el producte en entorns reals i obtenir casos d'ús concrets.

Canals de difusió previstos:

- Contactes directes amb responsables tècnics i d'experiència d'usuària de plataformes vídeo a la carta.
- Presentació en fòrums tecnològics o festivals de cinema digitals (com el SXSW, ISE, o festivals de narrativa immersiva).
- Col·laboracions amb escoles de cinema o universitats per a proves pilot.

A llarg termini, es podria plantejar una col·laboració amb distribuïdores de contingut o estudis independents que vulguin oferir les seves pel·lícules mitjançant una plataforma personalitzada.

5.8. Pressupost estimat

Per avaluar la viabilitat econòmica de la proposta presentada, s'ha estimat un pressupost orientatiu amb les partides més habituals en el desenvolupament d'aplicacions que combinen intel·ligència artificial i integració d'API. Aquestes estimacions es basen en tarifes mitjanes del mercat i fonts consultades. En aquells casos on no s'ha pogut accedir a una font oficial o pública, s'indica explícitament i s'evita atribuir xifres a fonts inexistents.

- Desenvolupament del SDK (6.000 – 8.000 €): Aquest rang es fonamenta en tarifes mitjanes de desenvolupadors freelance a Espanya, les quals oscil·len entre 30 i 50 € l'hora. Per a un projecte de 4 a 6 mesos de durada, a temps parcial o complet, aquest pressupost és justificat (Zaask, n.d.).
- Disseny d'interfície i experiència d'usuari (1.000 – 1.500 €): El cost s'ajusta a tarifes habituals de dissenyadors UX/UI a Espanya, que se situen entre 35 i 75 €/h segons l'experiència i la complexitat del projecte (Zaask, n.d.).
- Llicència comercial de TMDB (500 – 1.000 € anuals): TMDB no publica obertament els preus de les seves llicències comercials, vaig intentar contactar amb el seu equip per consultar un pressupost ajustat a les condicions del prototip, però no vaig rebre resposta. Per tant, el rang indicat és una estimació orientativa. Aquesta dada s'inclou com a referència estimada, però no prové d'una font oficial directa.
- Allotjament i servidor de proves (300 – 600 € anuals): El pressupost s'ha basat en els preus d'entrada dels serveis com Amazon Web Services, Google Cloud o DigitalOcean, que ofereixen instàncies bàsiques entre 25 i 50 € mensuals (Amazon Web Services, n.d.).
- Suport legal i protecció de dades (800 – 1.200 € inicials): L'adaptació a la normativa RGPD comporta costos variables segons la mida del projecte. Segons Ayuda Ley Protección Datos (2025), la mitjana per a serveis inicials de consultoria i redacció de documents legals se situa dins d'aquest interval.
- Màrqueting inicial i difusió (1.000 – 2.000 €): Aquesta estimació cobreix la creació d'una *landing page*, campanyes bàsiques en xarxes socials i difusió el línia. Tot i que hi ha molta variabilitat en funció del canal i abast, fonts com First Pier (n.d.) indiquen que aquest pressupost és viable per a accions inicials bàsiques.

- Viatges i desplaçaments (300 – 600 €): Inclou possibles despeses associades a reunions presencials amb possibles col·laboradors, esdeveniments de *networking* o participació en fires i presentacions. És una estimació a partir de despeses habituals de desplaçament dins del territori nacional (bitllets de tren, transport urbà, dietes bàsiques), preveient entre 2 i 4 sortides puntuals durant el període de desenvolupament del projecte.

En conjunt, aquest pressupost —entre 9.900 i 14.900 €— representa una aproximació realista per al desenvolupament, prova i llançament inicial d'una eina digital centrada en l'experiència d'usuari i l'anàlisi emocional. A manera de resum, es proporciona la següent taula:

Partida	Cost estimat (€)
Desenvolupament del SDK (4-6 mesos)	6.000 – 8.000
Disseny Interfície i experiència d'usuària	1.000 – 1.500
Llicència comercial TMDB	500 – 1.000 anuals
Allotjament i servidor de proves	300 – 600 anuals
Suport legal i protecció de dades	800 – 1.200 inicials
Màrqueting inicial i difusió	800 – 2.000
Viatges i desplaçaments	300 – 600
Total estimat	9.900 – 14.900

Taula 4. Cost estimat d'una MVP. Elaboració pròpia.

5.9. Viabilitat tècnica

Actualment, el model presentat compta amb dos recursos externs clau:

- L'API de TMDB, que proporciona la informació necessària sobre cada títol.
- El model DistilRoBERTa-base de Hugging Face, utilitzat per analitzar el sentiment del text introduït per la usuària.

Aquestes dependències, tot i facilitar un desenvolupament eficient i econòmic, suposen una limitació per a la seva explotació comercial:

- El model de Hugging Face requereix connexió als seus servidors. Si hi ha saturació o problemes de disponibilitat en qualsevol dels servidors implicats (plataforma de streaming,

Hugging Face o altres), això pot alentir els temps de resposta i empitjorar l'experiència de la usuària.

- L'ús de l'API de TMDb està subjecte a la seva llicència. És gratuït per a finalitats no comercials, però per a usos comercials cal una llicència de pagament.

5.10. Escalabilitat

L'escalabilitat és un aspecte clau, especialment en sistemes informàtics orientats a un ús real i potencialment massiu. Cal garantir l'adaptació a l'augment d'usuàries, peticions o noves funcionalitats sense perdre rendiment. Tot i que l'actual prototip no està dissenyat per a un ús comercial, les següents millores serien necessàries:

- Execució local del model d'anàlisi de sentiments: evitar la dependència de servidors externs com Hugging Face permetria reduir temps de càrrega i eliminar colls d'ampolla, especialment davant peticions simultànies.
- Creació d'una base de dades pròpia de pel·lícules: per reduir la dependència de TMDb, es podria gestionar una base de dades interna actualitzada periòdicament, ja sigui a partir de conjunts de dades amb llicència oberta o mitjançant acords comercials.
- Distribució en format SDK: com ja s'ha comentat, delegar el processament al client final facilita l'escalabilitat, ja que no cal una infraestructura centralitzada per atendre totes les peticions.

Al següent apartat es descriuen funcionalitats futures per millorar l'experiència d'usuària, més enllà de l'escalabilitat.

5.10.1. Futures funcionalitats

Em reitero un cop més dient que, tot i no haver acabat el prototip, hi ha diverses funcionalitats que es van quedar al tinter. Tot i no haver-se implementat, s'esmentaran una a una perquè, a posteriori de completar aquest treball, pugui continuar treballant amb un full de ruta ben marcat.

Des d'un inici vaig contemplar l'opció d'afegir una eina de reconeixement de veu per poder interpretar el text sense haver-lo d'escriure. Aquesta idea va sorgir de comprovar què ofereix cada dispositiu, fent

que la navegació a mòbil i, sobretot, a televisions modernes (amb micròfon al comandament o similar) sigui molt més còmoda per a aquelles persones que no volen escriure gaire. Aquesta funcionalitat es podria afegir amb alguna eina d'Amazon Web Services o Google Cloud.

Des de fa mesos, dins del treball, també vaig estar reflexionant amb diverses persones sobre si seria millor idea canviar la pregunta que se li fa a la usuària per una més simple, com ara "Com et vols sentir?". Això es deu a diversos motius:

- Practicitat. Al cap i a la fi, el que jo, com a desenvolupador, vull saber és com vull que se senti aquella persona per poder recomanar-li una pel·lícula. Saber com se sent pot ser interessant per extreure més informació per poder recomanar millor. Més enllà d'això, i també pel següent punt, crec que seria bona idea provar de canviar la pregunta.
- Alliberar càrrega computacional. Una aplicació d'aquesta mena, amb API webs i sistemes d'aprenentatge automàtic a la xarxa, té una problemàtica. Cada trucada que fem fa que el nostre dispositiu sigui l'encarregat de processar internament totes aquestes dades. Això, a primera vista, pot no ser problemàtic fins que l'eina s'usi en un dispositiu de baixes especificacions, en el qual la velocitat seria tan baixa que qualsevol usuària perdria les ganes d'utilitzar-la. En treure la part d'aprenentatge automàtic per interpretar el text, s'elimina un pas que l'eina hauria de processar cada cop.

D'igual manera, això és una teoria que es plantejaria per decidir si introdueix o no aquesta funcionalitat, fent més proves tant amb cinèfils com amb usuàries de l'aplicació.

Una altra funcionalitat que podria ser interessant és crear una base de dades amb totes les pel·lícules i sèries disponibles a TMDB i afegir una columna gràcies a (DistilRoBERTa) en la qual, en interpretar el títol i la sinopsi, s'indiqui quin sentiment està relacionat amb cada pel·lícula. Això serviria per substituir el model actual de recomanació basat en gèneres, que és una visió molt bàsica i poc precisa. Aquest procés també alliberaria càrrega computacional, ja que només caldria fer una vegada l'anàlisi de sentiments de les pel·lícules al meu ordinador, i després al dispositiu de la usuària només caldria buscar les pel·lícules a una base de dades no relacional, emmagatzemada en format .JSON o un llenguatge similar. Aquest canvi considero que afavoriria l'obtenció de resultats més optimitzats per fer més forta la relació entre l'eina i la usuària. Una persona només es voldrà quedar amb l'experiència si és gratificant. En aquest cas, es recomanaran pel·lícules rellevants i d'acord amb el sentiment que s'havia establert.

També es planteja la possibilitat d'integrar un sistema de retroalimentació actiu per part de la usuària. És a dir, que la persona pugui indicar si una recomanació li ha agradat o no. Això permetria que l'eina aprengués amb el temps i que les futures recomanacions fossin cada cop més ajustades als seus gustos personals. És un pas important cap a la personalització contínua sense haver de recollir dades invasives.

Relacionat amb això, es podria implementar un sistema de perfilat emocional: si s'identifiquen patrons a partir de les interaccions (com ara que una persona acostuma a mirar comèdies quan està trista, o thrillers quan està enfadada), es podrien anticipar les recomanacions segons aquestes dinàmiques personals, i no només segons una emoció puntual.

Un altre punt rellevant seria anar més enllà dels gèneres o sentiments literals i començar a representar semànticament cada pel·lícula amb models més avançats com *embeddings* obtinguts amb BERT. D'aquesta manera, no es compararia només per gènere, sinó per similitud conceptual, temàtica o de to narratiu, afavorint recomanacions més profundes i precises.

Finalment, també m'agradaria en el futur internacionalitzar l'eina, cosa que permetria detectar l'idioma del dispositiu i oferir la interfície en català, castellà, anglès o altres llengües. Aquest pas no només milloraria l'accessibilitat, sinó que obriria la porta a compartir l'eina amb persones d'altres territoris.

5.11. Aspectes legals i ètics

Per a l'explotació comercial, caldrà registrar la propietat intel·lectual del sistema i garantir el compliment de la normativa vigent respecte a la protecció de dades, especialment pel que fa a la informació emocional, considerada sensible. Caldrà complir el Reglament General de Protecció de Dades (RGPD) de la Unió Europea, que estableix que “les dades personals han de ser [...] adequades, pertinents i limitades al necessari en relació amb les finalitats per a les quals són tractades” (Art. 5.1.c). També s'hauran de seguir bones pràctiques d'ètica en la intel·ligència artificial, com ara la protecció des del disseny i el respecte als drets de les usuàries.

6. Conclusions

Aquest treball m'ha permès explorar, des d'una perspectiva tant tecnològica com emocional, la possibilitat de desenvolupar un sistema de recomanació cinematogràfica que va més enllà dels criteris habituals com l'historial de consum o les puntuacions de les usuàries. Partint d'un interès personal pel cinema i la voluntat de donar resposta a una problemàtica conjunta: no saber que consumir en cada moment, s'ha dissenyat i implementat un prototip capaç de generar recomanacions a partir de l'anàlisi de sentiments expressats en llenguatge natural.

El procés ha combinat la investigació teòrica i el desenvolupament pràctic, sempre aportant les meves reflexions crítiques. El model d'intel·ligència artificial usat, basat en DistilRoBERTa, ha demostrat una capacitat significativa per detectar emocions i traduir-les a gèneres cinematogràfics, oferint una experiència de recomanació més personalitzada. D'igual forma, s'han detectat una sèrie de limitacions, com la manca de detecció de llengües que no fos l'anglesa o la dificultat per interpretar emocions complexes com la ironia, així com barreres tècniques inicials relacionades amb la recollida de dades i la programació.

Malgrat aquestes limitacions, el projecte obre el camí a noves possibilitats que podrien millorar tant el seu rendiment com el seu abast. Algunes d'aquestes serien l'adaptació del model a altres idiomes com el català o el castellà, l'ampliació del sistema per a detectar emocions a través de veu o imatges, o fins i tot la seva integració en plataformes reals com podria ser Filmin o alguna de les plataformes competidores, aportant un valor afegit tant per als usuaris com per a les empreses.

En definitiva, aquest treball proposa un canvi d'enfocament: entendre que les emocions poden tenir un paper central en la presa de decisions digitals, i que la intel·ligència artificial no ha de ser només una “simple” eina de predicció, sinó també una eina de comprensió. En un context en el qual cada vegada tenim més dades, i que l'augment d'aquest és exponencial, però tenim menys temps, escoltar com se sent la persona usuària pot ser clau per a oferir una experiència més humana, rellevant i significativa.

Per finalitzar, aquest treball ha sigut molt més que un simple exercici acadèmic. Ha sigut una oportunitat per unir dues de les meves passions: el cinema i la tecnologia. Durant la realització d'aquest no només he après a desenvolupar una eina funcional, sinó a entendre millor com la tecnologia pot connectar amb les emocions humanes. M'he trobat de cara amb diversos sots, he hagut de deixar processos que havia començat per tornar a començar-los, equivocar-me i començar de zero, però

també he descobert la satisfacció de crear quelcom que pot arribar a tindre un impacte real en la forma que tenim de consumir contingut. Si una persona, en algun moment troba la pel·lícula que necessitava gràcies a una eina com aquesta, tota la dedicació implementada en aquest treball haurà valgut la pena.

7. Bibliografia

- Pang, B., & Lee, L. (2008). Opinion mining and sentiment analysis. *Foundations and Trends® in information retrieval*, 2(1–2), 1-135.
- Latorre, M. (2018). Historia de las web, 1.0, 2.0, 3.0 y 4.0. *Universidad Marcelino Champagnat*, 1. https://d1wqtxts1xzle7.cloudfront.net/59947315/74_Historia_de_la_Web20190706-123188-141xd95-libre.pdf?1562447605=&response-content-disposition=inline%3B+filename%3DHISTORIA_DE_LAS_WEB_1_0_2_0_3_0_y_4_0.pdf&Expires=1737823368&Signature=ZzjsR3uLPJkOSelKSYOzKFowUnXvKOPI5Cu8SdLhLd-EVY~JaqEFX5IWGUg-LwhxIGoo7Zy2vkkPEuKwb6Pgi0O~Ix0sbMDcwb0hXxqE20K-rzgHfdExUipYTEh3T9XEy2PJ-nrAGWXmBbjzfIDRIHi4XSH35vXfMv2WVwJPMY0JGGUGVnmtJSULSp5T3tq9UC6nA5xFx9cpJCZ2UPnIP~knuOhsqp4mpjQvZrqvLIH3BLXYIWPIKs8tvxPBRvvCbTp9Suj~hatctIPgcfssfSpZO L97RPyJo2fOEEe00MLdnkBpT9Qd9jtQvBLlg~kprnSp~cbsidDI7lV-5qur0w &Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA
- Ligthart, A., Catal, C., & Tekinerdogan, B. (2021). Systematic reviews in sentiment analysis: a tertiary study. *Artificial Intelligence Review*, 54, 4997 - 5053. <https://doi.org/10.1007/s10462-021-09973-3>
- Salıcı, M., & Ölçer, Ü. (2024). Impact of Transformer-Based Models in NLP: An In-Depth Study on BERT and GPT. *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1-6. <https://doi.org/10.1109/IDAP64064.2024.10710796>
- Pérez, A. A., & Close, J. G. (2015). Sistemas de recomendación. *Robots Autónomos: Navegación*. http://komputersapiens.smia.mx/files_ALMoStuNrEaChaBL/ks71_1.83MB_compacta.pdf#page=14
- Leskovec, J., Rajaraman, A., & Ullman, J. D. (2020). *Mining of massive data sets*. Cambridge university press. <http://infolab.stanford.edu/~ullman/mmds/book.pdf>
- González, O. E., & Jacques, S. M. (2017). Estado del arte en los sistemas de recomendación. *Res. Comput. Sci.*, 135, 25-40. https://rcs.cic.ipn.mx/2017_135/Estado%20del%20arte%20en%20los%20sistemas%20de%20recomendacion.pdf

Marcos Poza, J. (2019). *Estudio de las cookies: usos empresariales frente a las limitaciones legales y la percepción del consumidor*. <https://uvadoc.uva.es/handle/10324/40065>

Olguín, G. E. M., & De Jesús, Y. L. (2019). Métricas de similitud y evaluación para sistemas de recomendación de filtrado colaborativo. *Revista de Investigación en Tecnologías de la Información: RITI*, 7(14), 224-240. <https://dialnet.unirioja.es/servlet/articulo?codigo=7242764>

Ebesu, T. A. (2019). *Deep learning for recommender systems* (Doctoral dissertation, Santa Clara University).

https://scholarcommons.scu.edu/cgi/viewcontent.cgi?article=1021&context=eng_phd_theses

Yang, Y., Jang, H., & Kim, B. (2020). A Hybrid Recommender System for Sequential Recommendation: Combining Similarity Models With Markov Chains. *IEEE Access*, 8, 190136-190146. <https://doi.org/10.1109/ACCESS.2020.3027380>

Hajirahimi, Z., & Khashei, M. (2019). Weighted sequential hybrid approaches for time series forecasting. *Physica A: Statistical Mechanics and its Applications*. <https://doi.org/10.1016/J.PHYSA.2019.121717>

Gunawardana, A., & Meek, C. (2009). A unified approach to building hybrid recommender systems. , 117-124. <https://doi.org/10.1145/1639714.1639735>

Isita. (2024, 7 octubre). *Cómo Netflix utiliza la inteligencia artificial para transformar la experiencia del usuario*. <https://www.linkedin.com/pulse/c%C3%B3mo-netflix-utiliza-la-inteligencia-artificial-para-transformar-za7ke/>

Holgado, R. (2023, 16 novembre). *Dos gigantes unidos por la IA: Spotify usará la inteligencia artificial de Google para mejorar así tu experiencia en la app*. 20bits. <https://www.20minutos.es/tecnologia/inteligencia-artificial/spotify-google-inteligencia-artificial-mejorar-tu-experiencia-5190686/>

The Guardian. (2018, 10 octubre). *Amazon scrapped “sexist AI” tool that showed bias against women*. <https://www.theguardian.com/technology/2018/oct/10/amazon-hiring-ai-gender-bias-recruiting-engine>

The Guardian. (2024, 1 juliol). *Detroit changes rules for police use of facial recognition after wrongful arrest*. <https://www.theguardian.com/technology/article/2024/jul/01/detroit-police-facial-recognition-racial-bias>

- Clark, J. (2020). Application Programming Interface. *The SAGE International Encyclopedia of Mass Media and Society*. <https://doi.org/10.4135/9781483375519.n38>
- Tollerud, E. (2016). What is an API. , 31. <https://doi.org/10.5281/ZENODO.48447>
- Lakshmiraghavan, B. (2013). *Building a Basic Web API*. , 1-25. https://doi.org/10.1007/978-1-4302-6176-6_1
- Dashtipour, K., Gogate, M., Adeel, A., Larijani, H., & Hussain, A. (2021). *Sentiment Analysis of Persian Movie Reviews Using Deep Learning*. *Entropy*, 23. <https://doi.org/10.3390/e23050596>.
- Kumar, K., Harish, B., & Darshan, H. (2019). Sentiment Analysis on IMDb Movie Reviews Using Hybrid Feature Extraction Method. *Int. J. Interact. Multim. Artif. Intell.*, 5, 109-114. <https://doi.org/10.9781/IJIMAI.2018.12.005>.
- Frangidis, P., Georgiou, K., & Papadopoulos, S. (2020). Sentiment Analysis on Movie Scripts and Reviews. *Artificial Intelligence Applications and Innovations*, 583, 430 - 438. https://doi.org/10.1007/978-3-030-49161-1_36.
- Netflix. (s.d.). *Cómo funciona el sistema de recomendaciones de Netflix*. Recuperat el 7 de maig de 2025 a <https://help.netflix.com/es-es/node/100639>
- Parlamento Europeo y Consejo de la Unión Europea. (2016). *Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo, de 27 de abril de 2016, relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos (Reglamento general de protección de datos)*. Diario Oficial de la Unión Europea, L 119, 1–88. <https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=CELEX%3A32016R0679>
- Amazon Web Services. (n.d.). *AWS Pricing Calculator*. Recuperat el 26 de maig de 2025 a <https://calculator.aws/#/>
- Ayuda Ley Protección Datos. (2025, 21 abril). *¿Cuánto cuesta el servicio de consultoría en protección de datos?* <https://ayudaleyprotecciondatos.es/2025/04/21/cuanto-cuesta-servicio-consultoria-proteccion-datos/>
- Netflix. (2025, 21 gener). Number of Netflix paid subscribers worldwide from 1st quarter 2013 to 4th quarter 2024 (in millions) [Graph]. In Statista. Recuperat el 29 de maig de 2025 a

<https://www.statista.com/statistics/250934/quarterly-number-of-netflix-streaming-subscribers-worldwide>

Cinelytic | Built for a Better Film Business. (n. d.). Recuperat el 20 de maig de 2025 a <https://www.cinelytic.com/>

Movio, shaping the future of movie marketing. (n. d.). Recuperat el 20 de maig de 2025 a <https://www.movio.co/>

Wikipedia contributors. (2024, 10 novembre). *Jinni (search engine)*. Wikipedia. [https://en.wikipedia.org/wiki/Jinni_\(search_engine\)](https://en.wikipedia.org/wiki/Jinni_(search_engine))

Zaask. (n.d.). *¿Cuánto cuesta el diseño de UX/UI?* Recuperat el 29 de maig de 2025 a <https://www.zaask.es/cuanto-cuesta/disenio-de-ux>

Rossem, S., Tavernier, W., Colle, D., Pickavet, M., & Demeester, P. (2018). Introducing Development Features for Virtualized Network Services. *IEEE Communications Magazine*, 56, 184-192. - <https://doi.org/10.1109/MCOM.2018.1600104>

Annexos

Annex 1. Entrevista amb l'equip de Filmin

Bloque 1: Visión general

1. Breve introducción de la persona entrevistada.

Hola, muchas gracias por estar interesados en Filmin. Preferimos no indicar nuestro nombre, ya que las respuestas han sido revisadas por varias personas y consensuadas con varios equipos.

2. ¿Cómo describiríais el sistema de recomendación actual de Filmin?

Nuestro sistema de recomendación en Filmin se basa en una combinación de factores que nos permiten ofrecer sugerencias personalizadas a nuestros usuarios. Contamos con un sistema que analiza los gustos cinematográficos de cada usuario y los conecta con películas y series que podrían interesarle. Además, damos especial importancia a la curaduría manual, ya que nuestro equipo editorial selecciona y organiza contenidos en colecciones temáticas que complementan las recomendaciones automatizadas. Este enfoque híbrido nos permite mantener el equilibrio entre la personalización tecnológica y el criterio de curaduría que caracteriza a Filmin.

3. ¿Qué tipo de datos de usuario (visualizaciones, valoraciones, etc.) se tienen en cuenta para generar las recomendaciones?

Actualmente los únicos datos que influyen en los algoritmos de recomendación son los visionados de forma directa y las valoraciones de forma indirecta. Todavía no tenemos en cuenta otros datos como las películas guardadas y los títulos favoritos, aunque hay planes para hacerlo.

Bloque 2: Técnica y tecnología

4. ¿Utilizáis sistemas de filtrado colaborativo, basado en contenido o un enfoque híbrido? ¿Cuál ha sido la razón de esta elección?

En Filmin utilizamos un enfoque híbrido que combina heurística editorial y personalización por interacción. La razón es que nos permite mantener un equilibrio óptimo entre la personalización y nuestra identidad editorial. La heurística editorial nos permite asegurar que las recomendaciones mantienen la calidad y el enfoque cultural distintivo de Filmin, mientras que la personalización por

interacción nos ayuda a adaptar estas recomendaciones a los gustos individuales de cada usuario. Esta combinación nos permite ofrecer descubrimientos relevantes sin perder nuestra esencia como plataforma especializada en cine de autor e independiente.

5. ¿Aplicáis técnicas de inteligencia artificial o aprendizaje automático en vuestro sistema de recomendaciones? ¿Podríais compartir algún ejemplo?

No aplicamos IA ni aprendizaje automático, al menos de momento.

6. ¿Habéis explorado la posibilidad de incorporar análisis de sentimientos o emociones como variable en las recomendaciones?

No de manera directa. Actualmente, abordamos parcialmente este aspecto a través de nuestras colecciones temáticas curadas manualmente, donde agrupamos películas por estados de ánimo o sensaciones específicas. También con el recién desarrollo del nuevo Recomendador, preguntamos directamente sobre el estado de ánimo entre otros parámetros para poder afinar la recomendación dada.

Bloque 3: Usabilidad e interfaz

7. ¿Qué importancia tiene para vosotros el diseño de la interfaz en la efectividad del sistema de recomendaciones?

La interfaz juega un papel fundamental en la efectividad de nuestras recomendaciones. Un diseño claro y accesible es esencial para que los usuarios puedan descubrir y acceder fácilmente a los contenidos recomendados. Ponemos especial atención en cómo presentamos las colecciones temáticas, las recomendaciones personalizadas y las sugerencias "Si te gustó..." para que sean fácilmente identificables y navegables. También cuidamos que la información contextual (como sinopsis, puntuaciones y datos técnicos) esté bien integrada y ayude a los usuarios a tomar decisiones informadas sobre qué ver. La interfaz debe facilitar tanto el descubrimiento casual como la búsqueda específica de contenido.

8. ¿Recogéis feedback de los usuarios sobre las recomendaciones recibidas? ¿A través de qué medios o herramientas?

Sí, recogemos feedback de los usuarios a través de diversos canales. Por un lado, tenemos los datos directos de interacción como las valoraciones que los usuarios dan a las películas y los comentarios

que dejan en los títulos. Por otro lado, recibimos feedback a través de nuestro servicio de atención al cliente y nuestras redes sociales. También realizamos ocasionalmente entrevistas específicas para evaluar la satisfacción con diferentes aspectos de la plataforma, incluyendo las recomendaciones. Toda esta información es analizada y utilizada para mejorar

continuamente nuestro sistema de recomendaciones.

Bloque 4: Retos y futuro

9. ¿Cuáles son los principales retos que enfrentáis a la hora de ofrecer recomendaciones relevantes y personalizadas a gran escala?

Nos enfrentamos a varios retos importantes en la personalización de recomendaciones a gran escala. Uno de los principales es el llamado "cold start" con nuevos usuarios, cuando aún no tenemos suficientes datos sobre sus preferencias. También es un desafío mantener un equilibrio entre recomendar contenido similar a lo que el usuario ya ha visto y ofrecer descubrimientos nuevos que amplíen sus horizontes cinematográficos. Otro reto significativo es la gestión de nuestro catálogo dinámico, ya que los derechos de las películas cambian constantemente, lo que afecta a la consistencia de las recomendaciones. Por último, debemos asegurar que nuestras recomendaciones reflejen la identidad editorial de Filmin mientras proporcionamos sugerencias

personalizadas relevantes.

10. ¿Tenéis planes para evolucionar o innovar en vuestro sistema de recomendación en el futuro próximo?

Sí, continuamos evolucionando nuestro sistema de recomendación. Recientemente hemos lanzado el nuevo Recomendador, ya mencionado, que considera múltiples variables como el estado de ánimo del usuario, el tiempo disponible para ver contenido y preferencias más específicas sobre géneros y estilos cinematográficos. Actualmente, estamos trabajando en mejorar la integración de recomendaciones para conseguir un mejor equilibrio entre las recomendaciones algorítmicas y la curaduría manual, que son los dos pilares fundamentales de nuestra propuesta de valor. El objetivo es que ambos enfoques se complementen de manera más fluida y natural en toda la experiencia del usuario.

11. ¿Cómo abordáis los posibles sesgos algorítmicos y los dilemas éticos relacionados con la personalización de contenidos?

Nuestro enfoque se basa en mantener el equilibrio mencionado. Que las recomendaciones automatizadas sean una ayuda, pero siempre partiendo de colecciones creadas manualmente por nuestro equipo. Es importante remarcar que la curadoría editorial es fundamental en Filmin. También, cualquier uso de la automatización está revisado por el equipo, asegurando que promovemos la diversidad cinematográfica y cultural que nos caracteriza.

Annex 2. Git del prototip

Al següent enllaç és on es troben les carpetes de codi per fer funcionar el prototip en local.

https://github.com/d5t7b5/dtb_recommender