

Universidad de Lima
Facultad de Ingeniería y Arquitectura
Carrera de Ingeniería de Sistemas



CODRESS

Trabajo de suficiencia profesional para optar el Título Profesional de Ingeniero de
Sistemas

Diego Alonso Renteria Vidaurre
Código 20111037

Asesor
Hernando Andre Zurita Calderon

Lima – Perú
Noviembre 2020

CODRESS




TABLA DE CONTENIDO

RESUMEN	VII
ABSTRACT.....	VIII
CAPÍTULO I: INTRODUCCIÓN	1
CAPÍTULO II: CONCEPTOS Y FUNDAMENTOS	4
2.1 Sistemas de Recomendación	4
2.1.1 Sistemas de recomendación basados en Contenido	8
2.1.2 Filtrado Colaborativo	9
2.1.3 Filtrado colaborativo Item – Item	16
2.1.4 Recomendadores híbridos	16
2.2 Design Thinking	20
CAPÍTULO III: FUNDAMENTACIÓN DEL PROYECTO	23
3.1 Fundamentación de la deseabilidad del proyecto	23
3.1.1 EMPATIZAR	23
3.1.2 DEFINIR	26
3.1.3 IDEAR.....	27
3.2 Fundamentación de la viabilidad económica del proyecto	28
3.2.1 Ingresos	28
CAPÍTULO IV: DEFINICIÓN DEL PROYECTO.....	40
4.1 Diseño de propuesta de valor.....	40
4.2 Objetivos generales y específicos	46
4.2.1 Objetivo general.....	46
4.2.2 Objetivos específicos	46
4.2.3 Modelo de negocio propuesto	46
4.2.4 Roles de equipo de proyecto.....	48
4.2.5 Stack Tecnológico.....	49
CAPÍTULO V: DESARROLLO DEL PROTOTIPO	52
5.1 Prototipado	52
5.1.1 Mvp	52
5.1.2 Testeo	59

CONCLUSIONES.....	64
RECOMENDACIONES	65
GLOSARIO DE TÉRMINOS.....	66
REFERENCIAS.....	67
BIBLIOGRAFÍA.....	69
ANEXOS	70

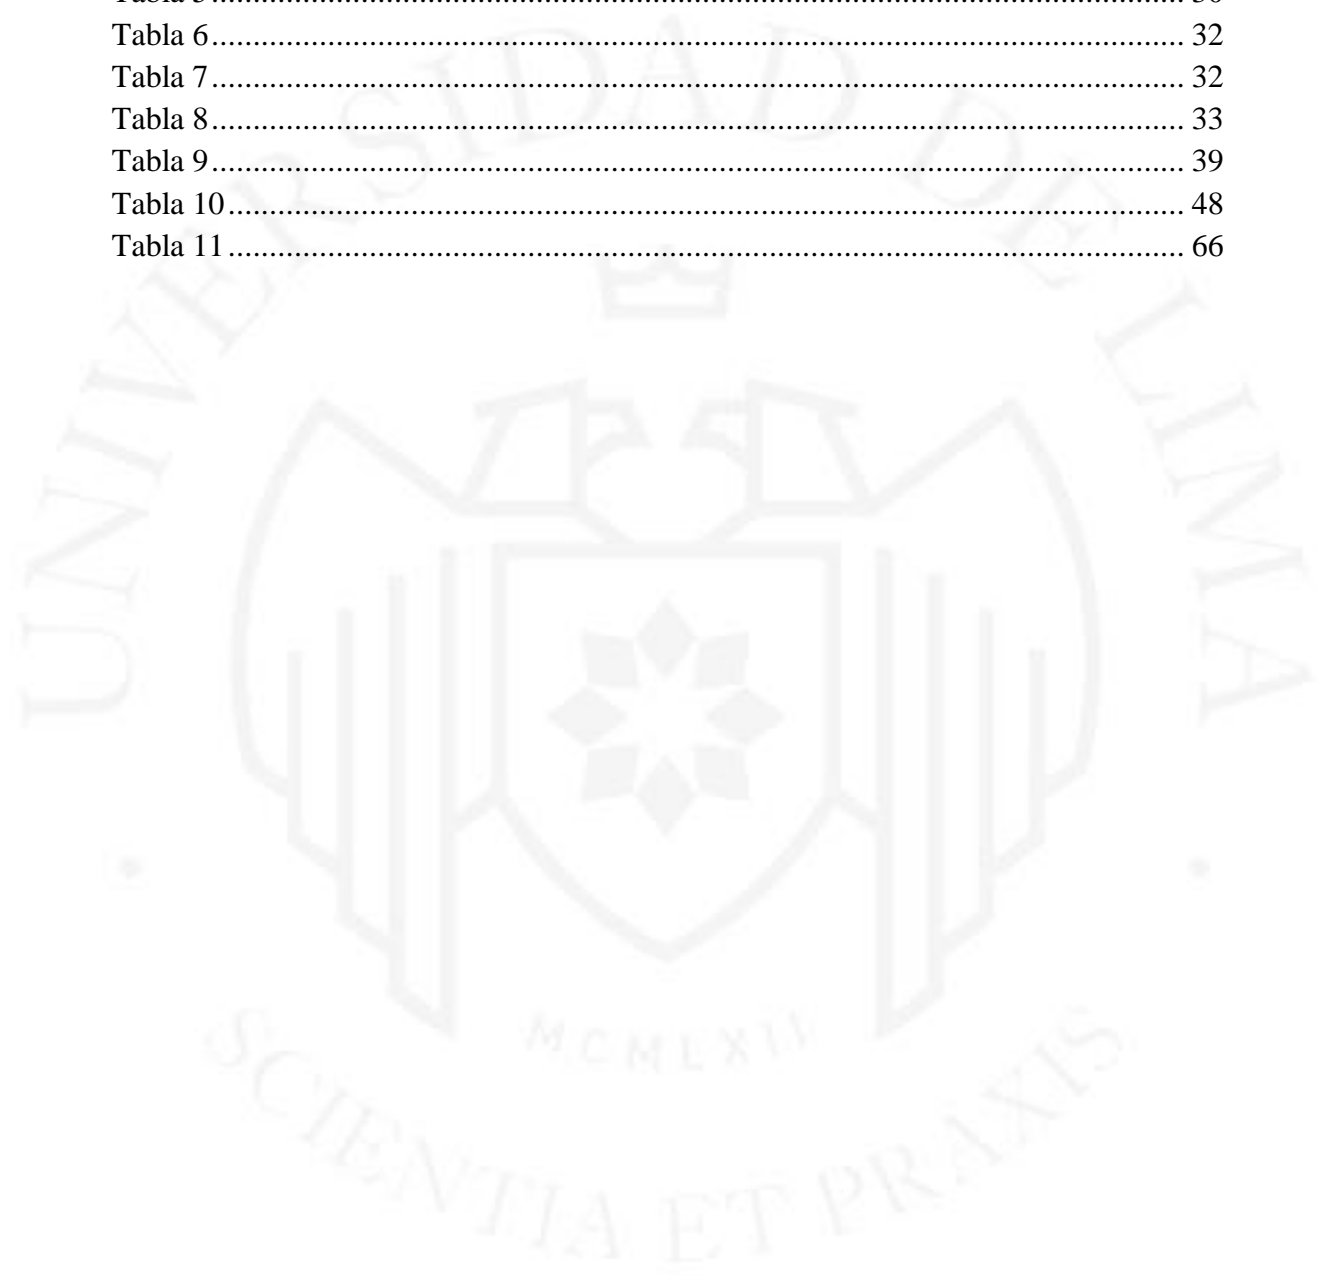


ÍNDICE DE FIGURAS

Figura 1.1 Motivos de gastos en el mercado peruano	2
Figura 1.2 Uso de Ecommerce en el Perú	3
Figura 1.3 Estadísticas de canales online	3
Figura 2.1 Esquema de proceso de una recomendación.....	5
Figura 2.2 Características de las diferentes formas de capturar las preferencias de los usuarios.....	6
Figura 2.3 Recomendación de productos relacionados al artículo deseado con su puntuación	7
Figura 2.4 Ejes representativos de la similitud de usuarios	14
Figura 2.5 Usuario activo	15
Figura 3.1 User Persona de usuario	24
Figura 3.2 Mapa de Empatía.....	25
Figura 3.3 Brainstorming y clusterización de ideas	27
Figura 3.4 Costo de inversión web	31
Figura 4.1 Definición de la propuesta de valor.....	41
Figura 4.2 Definición del MVP de Codress	46
Figura 4.3 Diagrama de Infraestructura de aplicación para el MVP	51
Figura 5.1 Prototipo a mano alzada	52
Figura 5.2 Diagrama de bloques de la propuesta.....	54

ÍNDICE DE TABLAS

Tabla 1.....	2
Tabla 2.....	26
Tabla 3.....	29
Tabla 4.....	29
Tabla 5.....	30
Tabla 6.....	32
Tabla 7.....	32
Tabla 8.....	33
Tabla 9.....	39
Tabla 10.....	48
Tabla 11.....	66



RESUMEN

El presente proyecto denominado “Codress”, es un servicio que busca cubrir la necesidad de vestimenta, mediante una plataforma digital web que permita a las personas alquilar ropa y/o vender ropa por internet, principalmente vestidos y accesorios en buen estado.

Está pensado en la mujer activa, social y llena de eventos, que sabe que no vale la pena gastar dinero en una ropa que no usará más de un par de veces. Así mismo, está orientado a personas, que tengan interés en alquilar y/o vender sus prendas y así obtener un ingreso extra, lo innovador de este proyecto es que te permite tener la información centralizada de diferentes marcas en un solo lugar, además de que el mismo brindará recomendaciones personalizadas en base a tus gustos personales con un algoritmo de recomendación.

Palabras Clave: Alquiler de ropa, experiencia de usuario orientada a mujeres, filtrado colaborativo

ABSTRACT

The present project called "Codress" is a service that seeks to cover the need for clothing, through a digital web platform that allows people to rent clothes and / or sell clothes online, mainly dresses and accessories in good condition.

It is intended for the active, social and eventful woman who knows that it is not worth spending money on clothes that she will not wear more than a couple of times. Likewise, it is aimed at people, who are interested in renting and / or selling their clothes and thus obtain an extra income, the innovation of this project is that it allows you to have centralized information from different brands in one place, in addition to it will provide personalized recommendations based on your personal tastes with a recommendation algorithm.

Keywords: Clothing rental, female-oriented user experience, collaborative filter

CAPÍTULO I: INTRODUCCIÓN

En el día a día, el tiempo es un factor limitante de muchas personas, ya que el tráfico de Lima y el trabajo absorben la mayor parte de la rutina diaria, “Según Gestión (2019), un limeño pierde en promedio 20 días al año atrapado en el tráfico”, lo cual les impide asistir a diversos lugares que quisieran visitar para satisfacer ciertas necesidades y/o gustos que se les presente.

Existen casos en donde los consumidores requieren de algún producto con urgencia, ya sea para un evento o por algún otro motivo en especial (boda, fiesta, salida, etc.), pero las tiendas por departamento que ofrecen dichos productos se encuentran alejadas y/o tienen horarios de atención limitados.

Ante tal necesidad, surgió el comercio electrónico, donde cualquier persona puede acceder a comprar cualquier producto desde la comodidad de su hogar, ya sea desde la página web de la marca ofertante o desde un aplicativo móvil con tan solo un click. Además, esta solución permite que las personas, tengan un mayor alcance de mercado, muchas veces sin contar con una tienda física como tal (por ejemplo, las empresas o personas que tienen una marca que solo vende por Instagram, Facebook, etc.). En el 2019 el e-commerce facturará más de 3 mil billones de dólares, a nivel mundial representando el 12.8% del total de ventas del retail (Ver tabla 1.1). Este estudio se realizó a 53 países, donde el Perú se ubicó dentro de los cinco países con mayor facturación online en Sudamérica con (US\$ 4 mil millones) y 68% en uso de internet como se puede apreciar en la figura 1.1

Tabla 1

Ventas Ecommerce por país

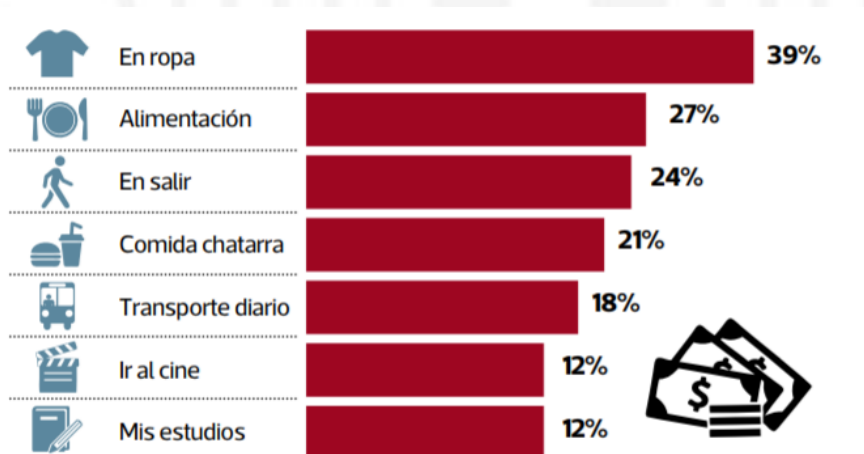
América

País	Ventas e-commerce	Porcentaje de penetración de Internet
EUA	\$504.582.000.000	88%
México	\$17.629.609.834	65%
Canadá	\$39.966.000.000	90%
Brasil	\$19.722.580.000	71%
Chile	\$5.888.000.000	78%
Argentina	\$4.260.738.000	93%
Colombia	\$4.000.000.000	63%
Perú	\$4.000.000.000	68%
Ecuador	\$800.000.000	80%
Venezuela	\$449.000.000	53%

Fuente: Linio

Según, “Euromonitor (2019), el mercado de e - commerce en el Perú, se duplicará en los próximos cinco años, siendo las categorías de moda, calzado y productos de consumo electrónico, los que representen el 50% de esta venta”, como se muestra en la figura.


Figura 1.1 Motivos de gastos en el mercado peruano



Fuente: Ipsos Perú

Todo esto viene impulsado por el auge de las tecnologías emergentes y por la masificación del internet que permite estar interconectados.

Figura 1.2 Uso de Ecommerce en el Perú



Fuente: Hootsuite (2019)

Figura 1.3 Estadísticas de canales online



Fuente: Visanet (2019)

Adicionalmente, esto viene apoyado por las relaciones interpersonales de las personas, que son la pieza fundamental para el desarrollo de los negocios, para lograr esto una persona tiene a asistir a muchos eventos, reuniones, fiestas, etc. Por ello, requiere de muchos atuendos de un solo uso, de forma rápida que resuelvan esta necesidad. Por ello, surge la idea de crear una plataforma digital web que permita a las personas alquilar ropa por internet, en buen estado.

CAPÍTULO II: CONCEPTOS Y FUNDAMENTOS

El objetivo de este capítulo es de presentar las bases teóricas que constituyen la base para el desarrollo del proyecto para una mejor comprensión del proyecto.

En primer lugar, se aborda los fundamentos de Sistemas de Recomendación.

A continuación, se explicará conceptos relativos a los métodos y métricas de evaluación de los mismos, así como de los campos de aplicación.

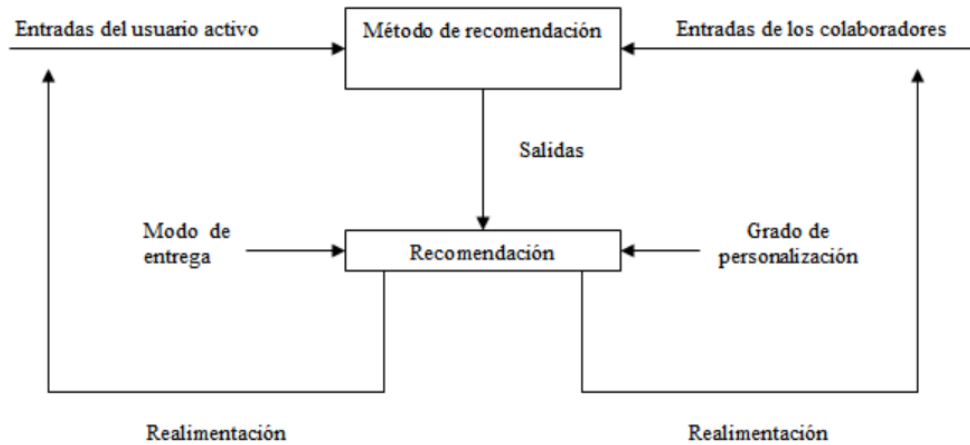
Adicionalmente, se presenta el tema de Design thinking que constituye la metodología de innovación utilizada en el desarrollo del proyecto.

2.1 Sistemas de Recomendación

Se define como un sistema que recoge y analiza las preferencias de las personas, generalmente en páginas web, comercios, redes sociales, sitios de noticias, etc. La premisa principal de estos, es que usuarios con actividades similares continúen compartiendo preferencias en el futuro. Cuando se sugiere a una persona servicios o tareas que otras personas con criterios afines han seleccionado anticipadamente (un mismo comportamiento), el nivel de acierto se inclina a ser superior al de las sugerencias basadas en preferencias sin personalizar. (como se cita en Gómez P, Guarda T, Cedeño J, et. al., 2018)

Se podría decir que los sistemas de recomendación tienen tres elementos: el primero, que serían los datos históricos (es la información que contiene el sistema antes de que comience el proceso de recomendación como tal), en segundo lugar, datos de entrada; que es la información que el usuario debe comunicar al sistema con el fin de generar una recomendación y un algoritmo que combine los dos elementos mencionados para llegar a sugerencias.

Figura 2.1 Esquema de proceso de una recomendación



Fuente: Gómez P, Guarda T, Cedeño J, et. al (2018)

Por este motivo, en la actualidad, su aplicación es cada vez más común, especialmente en los comercios electrónicos, que constantemente buscan atraer a potenciales compradores con productos de su total interés. Asimismo, los desarrolladores de sistemas de recomendación, han aplicado distintos enfoques para manejar y procesar todos los datos de los usuarios, pero el enfoque más utilizado es el de la recomendación colaborativa personalizada. Este tipo de recomendación lo utilizan grandes empresas como Amazon, Ebay, Netflix, Spotify, entre otros.

Estos sistemas, se denominan “personalizados” porque rastrean el comportamiento de cada usuario en páginas visitadas, compras realizadas, puntuaciones o reviews dados a artículos de interés, para así procesar y generar recomendaciones adaptadas a las necesidades y gustos de cada uno. Del mismo modo, son “colaborativas” porque relacionan los distintos artículos basándose en el hecho de que varios usuarios hayan comprado el mismo artículo (el bien común) o bien muestran cierta preferencia por ellos.

Según Formoso López (2013) , las preferencias de los usuarios son una de las principales fuentes de información usadas por los sistemas de recomendación, pues es a partir de ellas que el sistema obtiene información acerca de los gustos e intereses del usuario. Las preferencias pueden ser explícitas, en las que el usuario ofrece conscientemente su opinión sobre un producto, o implícitas, en las que esa opinión se extrae a partir de la interacción del usuario con el sistema. En un sistema con preferencias explícitas, el usuario se encarga de valorar los distintos productos según su

opinión. Generalmente, se utiliza un mecanismo basado en puntuaciones, en el que el usuario puntúa cada producto según su satisfacción con el mismo. A mayor número de puntos, mayor satisfacción. Por ejemplo, el sistema de recomendación de películas empleado por la plataforma Netflix utiliza una escala de 1 a 5 puntos, donde el usuario otorga una puntuación de 1 cuando una película no ha sido de su agrado, y 5 cuando le ha gustado mucho, permitiendo las puntuaciones intermedias (2, 3 y 4) reflejar distintos grados de satisfacción. Por otra parte, en un sistema con preferencias implícitas, la opinión del usuario se infiere a partir del uso que hace de la aplicación.

Figura 2.2 Características de las diferentes formas de capturar las preferencias de los usuarios

	 Implícitas	 Unarias	 Binarias	 Escala de puntuaciones
disponibilidad				
información aportada				
reflejan grado de importancia				
reflejan opinión negativa				
error y variabilidad				

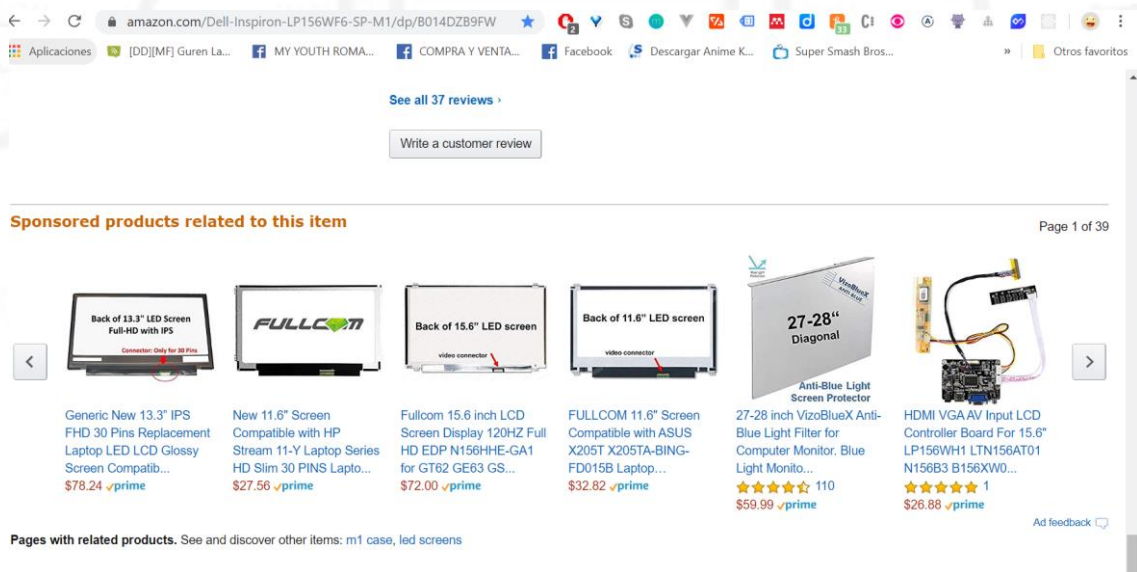
Fuente: López (2013)

La mayor ventaja de las preferencias implícitas es su mayor disponibilidad, pues durante el uso normal de la aplicación el usuario lleva a cabo numerosas acciones a partir de las cuales se pueden extraer las preferencias. Es decir, el sistema puede obtener información sobre los gustos o intereses del usuario sin necesidad de solicitársela en ningún momento. Por el contrario, las preferencias explícitas necesitan que el usuario esté dispuesto a transmitir su opinión. En principio, esto no debería suponer un problema, ya que el usuario obtiene una recompensa de su participación: mejores recomendaciones. Sin embargo, el interés del usuario no será el mismo en una aplicación que usa habitualmente y de cuyas recomendaciones obtiene un gran beneficio, que en otra aplicación que usa muy de vez en cuando y donde las recomendaciones tienen menor importancia para él. Por tanto, es necesario considerar

un cuidadoso diseño de la interfaz de usuario y del rango de puntuaciones a utilizar, alcanzando un compromiso entre la participación de los usuarios y el grado de información aportada por las puntuaciones que se adecue a cada aplicación.

En la actualidad, uno de los sistemas de recomendación más populares se puede encontrar en Amazon. En dicho sistema, cada usuario es una larga columna de números de una tabla muy grande que contiene datos que representan el comportamiento de los millones de usuarios de dicho sitio Web. Cada columna almacena datos sobre todo aquello que un usuario ha buscado, sobre aquellos ítems que un usuario ha pulsado, y todo aquello que el usuario haya comprado en dicho sitio Web. Esta columna varía cada vez que un usuario entra en el sitio Web, y cambia cada vez que un usuario realiza una acción dentro del sitio Web. Dicha información afecta al contenido que cada usuario visualiza en cada página que visita y también a los correos y ofertas personalizadas que cada usuario recibirá por parte de la compañía.

Figura 2.3 Recomendación de productos relacionados al artículo deseado con su puntuación



Fuente: Amazon

A raíz del aumento de información y la evolución de la tecnología han surgido diferentes aproximaciones para producir recomendaciones dadas. Podemos clasificarlos en tres tipos de sistemas de recomendación principales: basados en contenido, filtrado colaborativo e híbridos.

2.1.1 Sistemas de recomendación basados en Contenido

Un sistema de recomendación basado en contenido, también llamado content-based filtering, recomienda elementos similares a los que a un usuario le gustaba en el pasado, y construyen un modelo con el perfil de los intereses del mismo. En particular, se comparan varios elementos candidatos con elementos previamente calificados por el usuario (sistema de puntuación) y los mejores artículos son recomendados. (como se cita en Gadomavicius y Tuzhilin ,2005). Dicho de otro modo, se analiza la historia del usuario.

El proceso como tal, se podría resumir en tres etapas:

✓ **Analizador de contenido**

Básicamente es estructurar la data que se obtiene de diferentes fuentes de información (estructura el contenido de los artículos), en una forma adecuada para los siguientes pasos del procesamiento.

✓ **Construcción del perfil**

Consiste en recopilar datos de las preferencias del usuario. Para esto se utiliza técnicas de aprendizaje automático, con la finalidad de construir un modelo de los intereses del usuario a partir de los artículos que le gustaron o no en el pasado.

✓ **Componente de filtrado**

Se utiliza el perfil construido del usuario para sugerirle artículos relevantes, haciendo coincidir la representación del perfil frente a los elementos que serán recomendados. Como resultado se obtiene una lista clasificada de artículos potencialmente de interés para el mismo mediante el uso de algunas medidas de similitud.

Con el fin de construir y actualizar el perfil del usuario, las opiniones sobre los artículos se recopilan en un repositorio de retroalimentación. Estas opiniones ante diferentes ítems, son analizadas para predecir la relevancia real de un nuevo artículo.

2.1.1.1 Técnicas para analizar el contenido

- Modelo de espacios vectoriales basado en palabras clave (los artículos se representan como un espacio vectorial)
- Métodos probabilísticos y Native Bayes

- Modelo TF-IDF (es una medida numérica que representa la importancia que posee una palabra en un documento dentro de una colección).

2.1.2 Filtrado Colaborativo

Es una técnica para hacer pronósticos acerca de las preferencias de un usuario, en función de la información sobre los gustos de distintos usuarios. La suposición subyacente es que, si la persona A tiene la misma opinión que la persona B en algunos asuntos, entonces A es más probable tener opiniones similares como B sobre diferentes temas.

Según Fabra, U. P. (2004): *“Los algoritmos que se suelen usar para implementar las técnicas de filtrado colaborativo se llaman “métodos basados en vecindad”. Funcionan seleccionando un conjunto apropiado de usuarios, según la similitud de los mismos con respecto al usuario activo, y usan las valoraciones de dichos usuarios para generar la valoración del usuario activo”*. Concretamente, los tres pasos a seguir para realizar esto son los siguientes:

1. Medir la similitud de todos los usuarios con respecto al usuario activo.
2. Seleccionar un subconjunto de usuarios cuyas valoraciones se van a usar y, por tanto, tendrán influencia en la generación de la predicción para el usuario activo.
3. Normalizar las puntuaciones de los distintos usuarios y calcular una predicción a partir de algún tipo de combinación pesada de las puntuaciones asignadas al ítem por los usuarios seleccionados en el paso anterior.

Las dificultades que se podrían son:

- ✓ **Escasez de datos:** los sistemas de filtrado colaborativo se basan en conjuntos de datos. En ocasiones un problema común es empezar de cero (“cold start en inglés o arranque en frío”), ya que no se pueden recopilar preferencias con precisión y fiabilidad.
- ✓ **Sinónimos:** las diversidades de etiquetas con nombres similares a veces no son reconocidos por los sistemas de filtrados cuando en realidad el usuario está buscando el mismo elemento y se pierde información.
- ✓ **Haters o black sheep:** otra dificultad que afecta a los sistemas de filtrados son las opiniones de los usuarios que no están de acuerdo con

nada y todas sus recomendaciones son negativas, empeoran la calidad de las filtraciones.

- ✓ **Shilling attacks:** en los sistemas de recomendación cualquiera puede hacer evaluaciones, pudiendo un usuario votar positivamente sólo a sus productos y servicios y dar negativo a sus competidores, falseando la eficacia de esta herramienta.
- ✓ **Diversidad:** los filtros intentan buscar una diversidad para poder recomendar entre múltiples opciones. En ocasiones estos filtros van reduciendo esta variedad dando sólo visibilidad a los productos con mayor popularidad

Existen dos formas populares de filtrado colaborativo: basados en el usuario (User-based) y basados en productos (Items-based) (cómo se cita en Kaushik, Gupta, y Bhatia, 2018).

2.1.2.1 Filtrado colaborativo Usuario – Usuario

Describe que la recomendación del sistema se dará en base a los gustos del usuario, vale decir la similitud entre los mismos para predecir los niveles futuros de preferencia. De esta forma se va formando el perfil del usuario.

Por cada usuario se crea un conjunto de vecinos cercanos, usuarios cuyas valoraciones anteriores tienen grandes semejanzas a las del usuario en cuestión. Los resultados para los elementos no clasificados se predicen en base a la combinación de valoraciones conocidas (scores, ratings) realizados por los usuarios que son los vecinos más cercanos.

“Se podría decir que la recomendación se realiza en dos pasos, primero se buscan los usuarios que comparten los mismos patrones de evaluación con el usuario al que se va a recomendar y después se utilizan las evaluaciones de estos usuarios afines para calcular una predicción. Explicado de una manera más formal, podemos imaginarnos un escenario en el que tenemos n usuarios, $\{u_1, u_2, \dots, u_m\}$, y n elementos, $\{i_1, i_2, \dots, i_n\}$, y cada usuario tiene una lista de elementos, I_{u_i} , puntuados de forma explícita, por ejemplo, mediante una escala del 1 al 5, o inferidos de su comportamiento de forma implícita, por ejemplo viendo qué otros elementos ha comprado o en cuáles ha mostrado interés. Se obtiene así una matriz usuario-elemento de recomendación.” (como se cita en Miller B, Konstan J, Riedl J, 2004).

Algunas consideraciones sobre modelos basados en usuarios

- **Requiere evaluaciones previas:** Sin algunas evaluaciones de usuarios, no se tienen pistas sobre las evaluaciones de los nuevos usuarios o nuevos ítems.
- **No es una matriz densa:** Usualmente los usuarios dan su rating sobre algunos ítems y no sobre toda la base de datos, lo que puede dificultar algunos casos por falta de datos, pero puede ayudar ya que no se tiene que hacer los cálculos para todas las combinaciones posibles de usuario e ítems.
- **Altos costos si los perfiles de usuarios cambian:** Si los gustos cambian o hay ruido en los datos (ejemplo, 2 personas usan la misma cuenta en el sistema) todo el modelo del sistema debe que ser recalculado.

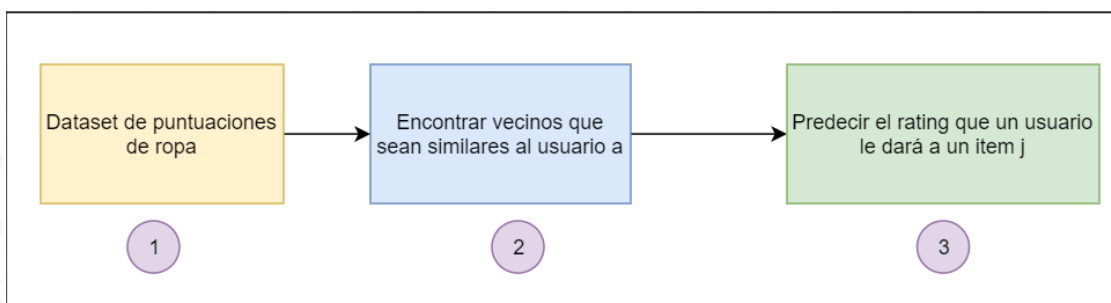


2.1.2.2 Aproximaciones

Una de las aproximaciones más utilizadas se detalla a continuación.

Vecinos más cercanos: para un ítem y un usuario dado, un subconjunto de usuarios es elegido basado en similitud con el usuario activo, y una combinación de pesos de las valoraciones dadas de ese ítem, son utilizadas para producir la predicción de valoración para ese usuario.

Dicho todo esto y aplicado como ejemplo al proyecto propuesto se podría diagramar en tres pasos.



Pasos para aplicar el filtrado colaborativo Fuente: Elaboración propia

Dataset de puntuaciones de ropa por usuario

Por ejemplo:

```
1 {
2   "dataset": {
3     "Alessandra Renteria": {
4       "Blusa marca H y M": "2.5",
5       "Polo marca mango": "3.5",
6       "Vestido color negro marca mango": "3.0",
7       "Vestido color coral marca sybilla": "3.5"
8     },
9     "Diandra Sanchez": {
10      "Blusa marca H y M": "3.0",
11      "Polo marca mango": "3.5",
12      "Vestido negro marca mango": "1.5",
13      "Vestido color coral marca sybilla": "5.0",
14      "Vestido color navy marca University Club": "3.5",
15      "Vestido color coral marca Basement": "4.5"
16    },
17    "Carolina Herrera": {
18      "Blusa marca H y M": "1.5",
19      "Polo marca mango": "2.5",
20      "Vestido color negro marca mango": "2.0",
21      "Vestido color coral marca sybilla": "2.5"
22    },
23    "Fatima Ventocilla": {
24      "Blusa marca H y M": "4.5",
25      "Polo marca mango": "4.5",
26      "Vestido color negro marca mango": "4.5",
27      "Vestido color coral marca sybilla": "4.5"
28    }
29  }
30 }
```

Fuente: Elaboración propia

Establecer similitud entre vecinos

Para establecer la similitud entre los vecinos de los que obtendremos la predicción debemos definir una medida que nos permita evaluar el grado de parecido entre unos y otros. Se podría utilizar la Distancia euclidiana o la correlación de Pearson como tal.

Distancia euclidiana

Es una de las formas más simples para calcular la similitud entre dos usuarios. Esto implica representar los datos como un punto en un gráfico (digamos eje x y eje y) y que

cada usuario tenga un punto, para nuestro caso de alquiler de ropa, por ejemplo, mujeres que les guste usar ropa casual (en el eje x) contra mujeres que le gusta usar ropa más formal, como para eventos sociales, matrimonios.


$$\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}$$

(1)

Fuente: “Introduction to Recommendation System in Javascript” (2018)

La siguiente figura muestra que Andrea se ha trazado en 3.5 en el eje de la ropa casual y 2.5 en el eje ropa formal. Cuanto más cerca esté un grupo de personas en el espacio de preferencias, más cerca estarán sus preferencias. Dado que el gráfico es bidimensional, solo puede ver pocos rankings a la vez.

Figura 2.4 Ejes representativos de la similitud de usuarios



Fuente: Elaboración propia

Correlación de Pearson

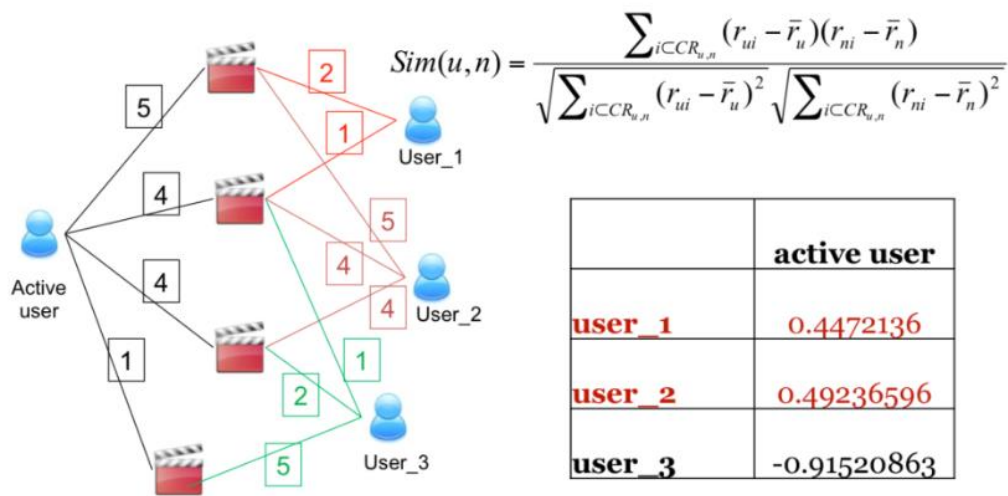
Un algoritmo que sirve para encontrar la similitud entre 2 sujetos es utilizar la Correlación de Pearson que nos entrega un índice que puede utilizarse para medir el grado de relación de dos variables siempre y cuando ambas sean cuantitativas. El

siguiente ejemplo muestra como calcular cuanto se parece un nuevo usuario, llamado el “active user”, con respecto a otros 3 usuarios dados.

$$r = \frac{\sum XY - \frac{\sum X \sum Y}{N}}{\sqrt{\left(\sum X^2 - \frac{(\sum X)^2}{N}\right)\left(\sum Y^2 - \frac{(\sum Y)^2}{N}\right)}}$$

(2)

Figura 2.5 Usuario activo



Fuente: “Tipos de RS: Filtrado Colaborativo – Sistemas de Recomendación” (2017)

Lo anterior se puede utilizar ahora para predecir cuanto es el rating que podría dar un usuario dado respecto a un ítem (en este caso, una película) que no ha visto.

La función devolverá un valor entre -1 y 1. Un valor de -1 significa que no están cerca o son similares, y un valor 1 significa que las dos personas tienen exactamente la misma calificación para cada elemento.

Predecir el rating

Luego de que se haya creado el puntaje de similitud entre los usuarios vecinos, utilizando las medidas propuestas, se debe crear una forma para clasificar al usuario en relación con el usuario que queremos, es decir, encontrar otro usuario que tenga el mismo gusto por otro vestido para nuestro caso. Para ello, se debe puntuar los elementos produciendo una puntuación ponderada que clasifique a los críticos, luego tomar los votos de todos los demás críticos y multiplicar cuán similares son al usuario que

queremos por el puntaje que dieron a cada vestido. El detalle de la implementación de esta función se puede encontrar en el capítulo de Desarrollo del prototipo.

2.1.3 Filtrado colaborativo Item – Item

El filtrado colaborativo basado en productos, dice que la recomendación del sistema se dará en base a los productos, vale decir los productos que los usuarios hayan visto previamente, se utilizará como base para predecir los niveles futuros de preferencia. A diferencia del filtrado colaborativo basado en contenido, la similitud se calcula a partir de las valoraciones, no del contenido (características de los productos). Este tipo es ideal para un escenario donde existen muchos usuarios y pocos ítems, ya que un ítem promedio tiene más valoraciones que un usuario promedio, y las similitudes entre los ítems, según las valoraciones no tienden a cambiar a lo largo del tiempo.

2.1.3.1 Aproximaciones

La idea es calcular como de similares son con el ítem destino i y seleccionar los k ítems más similares $k_1, k_2 \dots k_k$, así como sus correspondientes similitudes. Una vez que los ítems más similares son encontrados, la predicción es calculada tomando un promedio ponderado de las valoraciones del usuario en estos ítems similares.

2.1.4 Recomendadores híbridos

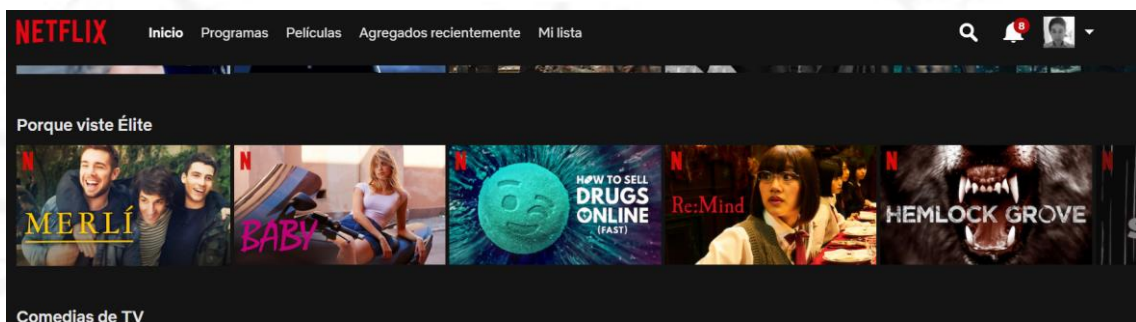
Tanto los enfoques basados en contenido como los colaborativos tienen sus propias fortalezas y debilidades y uno puede terminar con un mejor sistema combinando muchos algoritmos en lo que llamamos un enfoque híbrido. Los sistemas híbridos aprovechan tanto los datos de artículos como los datos de transacciones para dar recomendaciones.

A modo de ejemplo, un sistema de Filtrado Colaborativo y un sistema basado en contenido podrían combinarse, de manera que este último, podría compensar el problema del “arranque en frío”, proporcionando recomendaciones a los nuevos usuarios cuyos perfiles son demasiados pequeños para utilizar la técnica de filtrado

colaborativo, y este puede aportar la fortaleza que tiene en encontrar usuarios que comparten nichos inesperados que ninguna técnica basado en contenido podría haber predicho.

Un gran ejemplo del uso de un enfoque híbrido es el de Netflix como se explicó anteriormente. En Netflix, las recomendaciones no solo se basan en los hábitos de observación y búsqueda de las personas (sistemas colaborativos) sino que también se recomiendan películas que comparten características similares (basadas en el contenido).

Figura 2.6 Recomendación de películas, series en base a historial de visualización



Fuente: Netflix

Según Burke (2002) introduce la taxonomía de los SR híbridos, clasificándolos en siete categorías.

- **Híbrido Ponderado:** Este híbrido combina las valoraciones de cada componente utilizando una fórmula lineal. Por lo tanto, los componentes deben ser capaces de producir su puntuación de recomendación y debe ser linealmente combinable.
- **Híbrido de conmutación:** Consiste en la selección de un recomendador entre los candidatos. Dicha selección se realiza de acuerdo a la situación que se está viviendo; debe de existir un criterio para la selección, como valor de confianza o criterios externos y los componentes podrían tener un rendimiento diferente con distintas situaciones.
- **Híbrido Mixto:** Este tipo de híbrido se basa en la fusión y la presentación de múltiples listas de puntuaciones en una sola. Cada componente debe ser capaz de producir listas de recomendaciones con filas y el algoritmo del híbrido mixto la combina en una lista ordenada.
- **Híbrido basado en contenido de Características:** Existen dos componentes de recomendación muy diferentes de este híbrido, que son el contribuyente y el

recomendador real. El recomendador real trabaja con los datos modificados por el recomendador contribuyente, y el contribuyente inyecta características de una fuente a la fuente del recomendador real.

- **Híbrido basado en aumento de características:** Este híbrido es similar a los híbridos mencionados en el punto anterior, pero diferente en que el contribuyente genera nuevas características. Es más flexible y añade un menor número de dimensiones que el método de combinación de características.
- **Híbrido en cascada:** Esta técnica de recomendación se utiliza para producir una clasificación amplia de los candidatos y una segunda técnica que refina la recomendación entre el conjunto de los candidatos. El segundo paso se centra solo en aquellos elementos que requieren una discriminación adicional.
- **Híbrido Meta-nivel:** En esta técnica el modelo generado por el contribuyente se utiliza como entrada para el algoritmo del recomendador real.

2.1.4.1 Métricas de evaluación

A continuación, se presenta las métricas de evaluación más importantes. básicamente, vendrían a ser medidas utilizadas en la evaluación de las estrategias de búsquedas de información.

- **Precisión en la predicción:** Estas métricas, que se utilizan principalmente en la tarea de predicción, se basan en medir el error o diferencia entre la predicción hecha por el algoritmo y la puntuación real del usuario, usualmente expresado en porcentaje. Generalmente, el proceso de evaluación consiste en escoger un conjunto de evaluación formado por pares usuario-producto para los que se conoce la puntuación real hecha por el usuario. Las medidas de error más populares son el error absoluto medio (MAE), definido como el error absoluto medio y la raíz del error cuadrático medio (RMSE), definido como la diferencia entre las valoraciones estimadas y las valoraciones reales.

$$\text{Precisión} = \frac{(\text{documentos relevantes})}{(\text{documentos recuperados})}$$

- **Precisión en la clasificación.** Estas métricas, que se utilizan principalmente en la tarea de recomendación, evalúan si los productos recomendados por el

algoritmo son realmente adecuados a las preferencias del usuario. Generalmente, en la evaluación se selecciona un conjunto de usuarios, y se obtiene una recomendación para ellos utilizando el algoritmo. Luego se comparan los productos recomendados con aquellos que realmente son adecuados para cada usuario. Para tal fin, se pueden utilizar varias métricas, entre las que destacan la precisión y la exhaustividad o recall, que miden el ratio entre los productos relevantes que han sido recomendados, y, respectivamente, el total de productos recomendados o el total de productos relevantes.

2.1.4.2 El problema de cold-start (arranque en frío)

Las técnicas de filtrado colaborativo, y en particular los algoritmos basados en vecindad, obtienen muy buenos resultados cuando se tiene mucha información sobre los usuarios, es decir, cuando estos han puntuado un gran número de productos, pero empeoran a medida que dicha información disminuye.

En muchas aplicaciones reales sucede que la información es por lo general escasa. Por ejemplo, en un sistema de recomendación de películas, lo normal es que un usuario solo vea un pequeño porcentaje de las películas que se estrenan cada año, por lo que difícilmente va a puntuar más que unos pocos productos.

Este problema se puede dar básicamente cuando:

- ✓ Cuando se añade un nuevo producto al sistema, que por tanto todavía nadie ha puntuado.
- ✓ Cuando un nuevo usuario se registra en el sistema.
- ✓ Cuando se lanza un nuevo sistema o aplicación de recomendación.

Por otro lado, Arranque en frío de productos significa que un nuevo producto se lanza al mercado o se agrega al sistema. La acción del usuario es lo más importante para determinar el valor de cualquier producto. Más la interacción que recibe un producto, más fácil es para nuestro sistema recomendar ese producto al usuario correcto. Podemos hacer uso del filtrado basado en contenido para resolver este problema. El sistema primero usa el contenido del nuevo producto para recomendaciones y luego, eventualmente, las acciones del usuario sobre ese producto.

Por ejemplo, en Netflix, se le pide al usuario que elija algunos títulos que le gusten para ayudar a "poner en marcha" sus recomendaciones como nuevo usuario. Si no elige

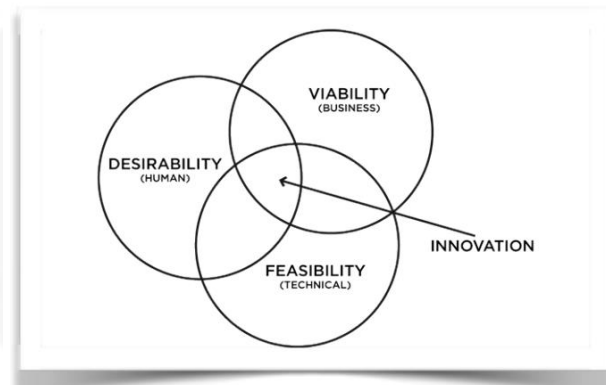
ninguno, se le mostrará una opción genérica de títulos populares y su actividad a partir de ese momento será la base del proceso.

2.2 Design Thinking

Es un proceso de innovación, innovador que enfatiza la observación, colaboración, aprendizaje rápido, visualización de ideas, rápido. Concepto de prototipado y análisis empresarial concurrente (Lockwood, 2009).

Brown (2017) plasma que el pensamiento de diseño se centra en la definición de innovación, que viene a ser la unión de las 3 fuerzas, deseabilidad, factibilidad y viabilidad

Figura 2.7 Definición de una satisfactoria innovación: Intersección de 3 fuerzas: deseabilidad, factibilidad y viabilidad



Fuente: Tim Brown (2017)

Como enfoque, el Design Thinking no solo se centran en la creación de productos y servicios, se basa en la capacidad para: ser intuitivo, reconocer patrones, construir ideas con significado emocional, funcional, y expresarse en los medios de comunicación que no sean palabras o símbolos, Santa-Olalla, B. (2018). En por ello que desde años atrás Buchanan (1992) afirma:

De hecho, los signos, las cosas, las acciones y los pensamientos no solo están interconectados, sino que también el interpenetrarse y fusionarse en el pensamiento de diseño contemporáneo tiene sorprendentes consecuencias para la innovación. Estas

áreas sugieren el linaje del pasado del diseño y presente, así como señalar hacia dónde se dirige el diseño en un futuro (p. 9).

En el artículo de Castillo V (2014) muestra las 5 etapas o pasos fundamentales del Design Thinking, como se puede observar en la figura 2.8

Figura 2.8 Etapas del Design Thinking



Fuente: “De Edison a Tim Brown: algunas ideas sobre Design Thinking” (2018).

A continuación, se va a detallar la definición por cada etapa del Design Thinking y que técnica es la que se utilizara en cada una, en el desarrollo del proyecto.

2.2.1.1 **Empatía**

Profunda comprensión de las necesidades de los usuarios implicados en la solución que estemos desarrollando, y también de su entorno. Es la etapa inicial en este proceso ya que se debe ser capaz de ponerse en la piel de dichas personas para encontrar soluciones consecuentes a sus realidades.

Técnica utilizada:

- Mapa de Empatía: Es una herramienta que permite personalizar, caracterizar y conocer a tu segmento de clientes. Se proponen con esta técnica preguntas como: ¿Que OYE?, ¿Que PIENSA y SIENTE?, ¿Que VE?, Que DICE Y HACE?

2.2.1.2 **Definir**

Etapa que permite entender la realidad la realidad existente, poniéndose en el lugar del usuario tipo, es filtrar la información recopilada en la etapa de empatía y quedarse con lo que realmente aporta valor(“Insights”), identificar problemas cuyas soluciones serán clave para la obtención de un resultado innovador.

Técnica utilizada:

- ¿Qué, cómo, por qué?: Aumentar la capacidad de la observación mediante una oración de lo que el usuario necesita y por qué. Tomar fotos.

USUARIO + NECESIDAD + INSIGHT

Por ejemplo: *“La familia Renteria necesita conectarse porque los momentos en familia son muy importantes.”*

Mediante esta afirmación nace una pregunta: ¿Cómo se puede generar un espacio para que toda la familia se conecte y comparta?

2.2.1.3 **Idear**

Generación de un sinnúmero de ideas que permitan generar la solución visionaria a implementar, para esto se deben eliminar los juicios de valor, vale decir que todas las ideas son bienvenidas y no se debe preocupar por incurrir en el error.

Técnica utilizada:

- Brain storming (Lluvia de ideas)

2.2.1.4 **Prototipar**

Volver las ideas en realidad, construir el MVP (Mínimo producto viable). Aquello que es indispensable como primera instancia en nuestra solución propuesta para aportar valor.

Técnica utilizada:

- Diseño de Prototipos a alto nivel

2.2.1.5 **Evaluar**

Compartir la idea con uno o varios usuarios para conocer la retroalimentación (feedback). Esta fase es crucial ya que nos ayudara a identificar mejoras significativas, fallos a resolver, posibles carencias en la solución.

Técnica utilizada:

- Preparación del Prototipo

CAPÍTULO III: FUNDAMENTACIÓN DEL PROYECTO

3.1 Fundamentación de la deseabilidad del proyecto

Cuando los números de eventos sociales se juntan, la pregunta que todas las mujeres se hacen es: ¿Qué me pongo? Escoger un vestido de noche sin duda es una tarea que requiere tiempo, tanto para seleccionar la prenda adecuada, la cual tendrá que cumplir el total de las expectativas en tendencias, moda, colores, temporadas, etc. ¿Será posible tomar la mejor decisión de compra sin excederse del presupuesto?, ¿Comprar un vestido solo para lucirlo una vez?, ¿Importa más la marca o el precio?, ¿Comprar o alquilar? Dada esta problemática para la mujer de conseguir el vestido ideal, se plantea:

“Codress”, cuyo propósito es facilitar el proceso de búsqueda y adquisición de vestimenta (principalmente vestidos), a través de una plataforma digital en mujeres socialmente activas que tienen muchos eventos, pero que ven tedioso invertir en ropa de un solo uso, además no cuentan con el tiempo adecuado para buscar la prenda adecuada, cuyo valor agregado será brindarles recomendaciones personalizadas en base a los gustos personales de cada persona mediante un algoritmo de recomendación.

Se utilizó la metodología de design Thinking para el desarrollo de la propuesta que se detalla a continuación.

3.1.1 EMPATIZAR

Se ha desarrollado una investigación exploratoria mediante entrevistas, ver anexo 1, (20 mujeres entre 20 y 30 años socialmente activas), para así conocer un poco más sobre sus preferencias de compra.

La exploración permitió conocer las necesidades descritas por el mismo usuario, Identificar sus necesidades y conocer la forma en que el usuario los resuelve, así como conocer a la persona que tiene estos vestidos, sólo lo ha utilizado una vez y consideraría la opción de alquilarlos para recuperar dicha inversión.

Las entrevistas como tal se dieron en áreas fuera de su entorno de trabajo de manera que se los participantes se sienten cómodos y pueden expresarse.

La guía de entrevista se encuentra en la sección anexos, donde se detallan las preguntas que se realizaron a cada una de los entrevistadas.

Las respuestas fueron transcritas a post-its y se agruparon de acuerdo con su similitud o si definían una misma idea y así encontrar patrones que resuman lo que el usuario estaba sintiendo o pensando y que sea representativo.

3.1.1.1 User Persona

En base a estas entrevistas se sacaron perfiles destacados que representan los patrones encontrados en base a nuestra entrevista para conocer más sobre potenciales usuarios y sus motivaciones.

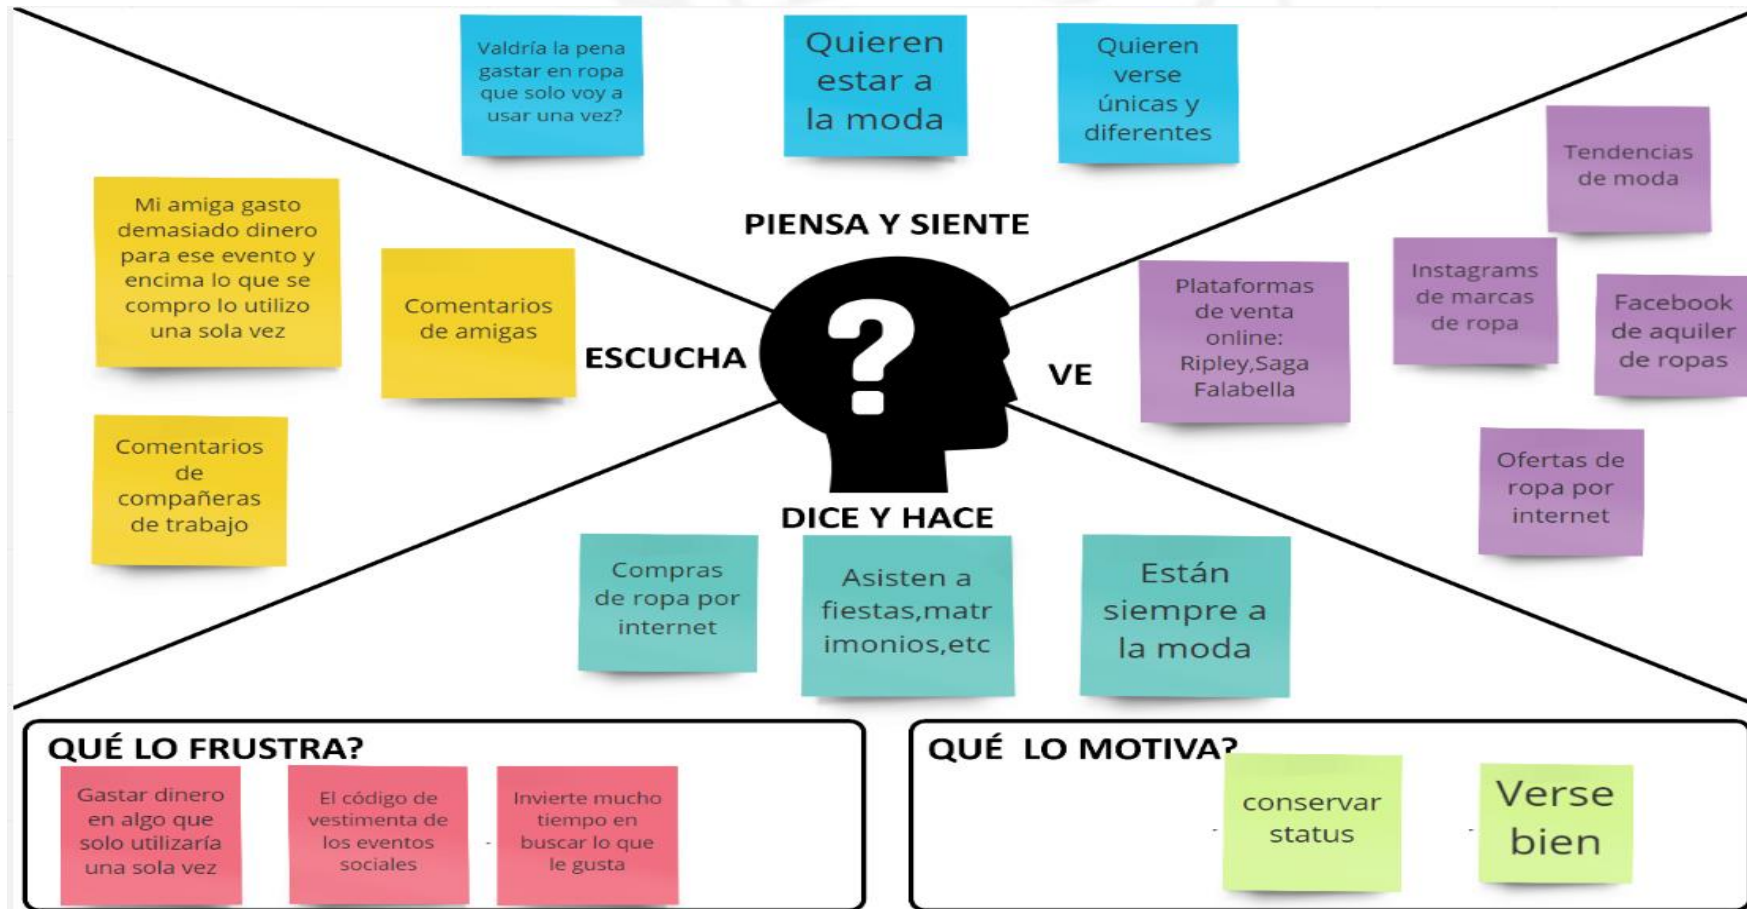
Figura 3.1 User Persona de usuario

Mafer			
Mujer entre 20 y 30 años socialmente activa que le gusta verse bien y comprar ropa de moda por internet.			
Hechos	Molestias	Comportamiento	Objetivos
Mujer entre 20 y 30 años, que le gusta verse, salir con sus amigas a eventos y comprar ropa de moda por internet o en tiendas por departamento.	No tener tiempo para ir a comprar ropa para los eventos, que la ropa que busca para un evento no le guste. El gasto que tiene que incurrir al comprarse un vestido que utilizará una sola vez.	Busca diversidad opciones de modelos, colores, calidad y precio a la hora de comprar ropa. Aprovecha las ofertas por ejemplo los descuentos por el cyberday.	Sentirse bien y verse bien con la ropa que usa. Conservar status.

Fuente: Elaboración Propia (2019)

A partir del perfil del usuario, se ha desarrollado el mapa de empatía para tener más claro el perfil de nuestro cliente ideal.

Figura 3.2 Mapa de Empatía



Fuente: Elaboración Propia (2019)

En las entrevistas se detectó las principales clientes, los “Early Adopter”, las cuales tendrán un protagonismo importante pues serian nuestras primeras compradoras y aquellas que darán a conocer nuestros servicios y destacarán los atributos de los mismos.

Las cuales tendrían la siguiente característica:

- Compradoras online que evidencian un problema en particular con las plataformas tradicionales de compra o alquiler, están pendientes de los nuevos avances en la web y les emociona la aparición de nueva tecnología y están siempre probándola.
- Las mujeres que alquilan vestidos por un canal tradicional, ya sea tienda física o por internet, que consideran dichos medios como las únicas soluciones a sus problemas de buscar vestidos, aunque no estén satisfechas en su totalidad.

3.1.2 DEFINIR

Se encontró un patrón en los usuarios basado en sus necesidades x insight, ver tabla 2.

Tabla 2

Definición de usuario - necesidad

Usuario	Necesidad	Insight
Mujer socialmente activa entre 20 y 30 años que le gusta verse bien y comprar ropa de moda por internet.	Ayuda para encontrar vestidos ideales que les permita asistir a distintos eventos de una forma rápida y barata.	Invierten mucho tiempo buscando vestidos para cada ocasión y no ven justificada la necesidad de invertir en ropa de un solo uso.
Mujer socialmente activa entre 20 y 30 años que le gusta verse bien y comprar ropa de moda por internet.	Ayuda para lograr tener el código de vestimenta adecuado para cada evento social de una forma rápida y sencilla.	Invierten mucho tiempo buscando la ropa ideal y sienten muchas veces que la que encuentran en ese momento no se adecua a necesidades personales.

Fuente: Elaboración Propia (2019)

3.1.3 IDEAR

Luego, se realizó una lluvia de ideas o brainstorming de acuerdo con el descubrimiento del insight previamente explicados para encontrar la solución, ver figura 3.3

Figura 3.3 Brainstorming y clusterización de ideas

¿Cómo se podría ayudar a las mujeres a encontrar vestidos que les permita asistir a distintos eventos de una forma rápida y barata?



Fuente: Elaboración Propia (2019)

De esta etapa se obtuvo la posible solución planteada, la cual es implementar una plataforma digital de alquiler de vestidos para personas mujeres socialmente activas con la combinación de un algoritmo de recomendación en base a los gustos personales de cada persona.

3.2 Fundamentación de la viabilidad económica del proyecto

3.2.1 Ingresos

3.2.1.1 Cálculo de la demanda de usuarios

Son seis millones de personas que compran por internet en el país. “Estamos hablando de cerca de 20% de peruanos que ya experimentan las compras online a través de diversas modalidades”, señala Jaime Montenegro, gerente de Comercio Electrónico de la CCL. De este número el 54.4% son mujeres y el 45.6% son varones. Hoy en día el 50% de las personas que compran residen en Lima y el otro 50% en las otras regiones del país (Gestión, 2019)

A continuación, se presenta la demanda potencial considerando tres factores:

- Promedio del número de personas que compran ropa por internet
- El porcentaje de mujeres que compran ropa por internet.
- El porcentaje de las personas que compran por internet que residen en Lima.
- El porcentaje de personas cuya modalidad de pago es con una tarjeta bancaria.

3.2.1.2 Egresos

Se invertirá S/ 220654 para poder cubrir el capital necesario para el gasto pre operativo y la adquisición de activos fijos como saldo inicial. La inversión se financiará con el aporte de capital de dos socios fundadores a una rentabilidad del 7%.

Los supuestos considerados fueron los siguientes:

- La tasa de cambio del dólar a es de S/ 3.365.

Tabla 3***Detalle de Gastos de Activos Fijos***

Activos fijos	Monto
MacBook Pro x 2 miembros del equipo	S/ 12,000.00
Útiles de oficina	S/ 400.00
Total	S/ 12,400.00

Fuente: Elaboración propia.

Se tiene el detalle del gasto de los implementos a utilizar para el desarrollo del MVP.

Tabla 4***Detalle del gasto único***

Gasto único	Total
Constitución de la empresa	S/ 1,500.00
Registro de la marca	S/ 750.00
Total	S/2250.00

Fuente: Elaboración propia.

Se tiene el detalle del gasto para la constitución de Codress como marca.

Tabla 5***Detalle de gastos mensuales***

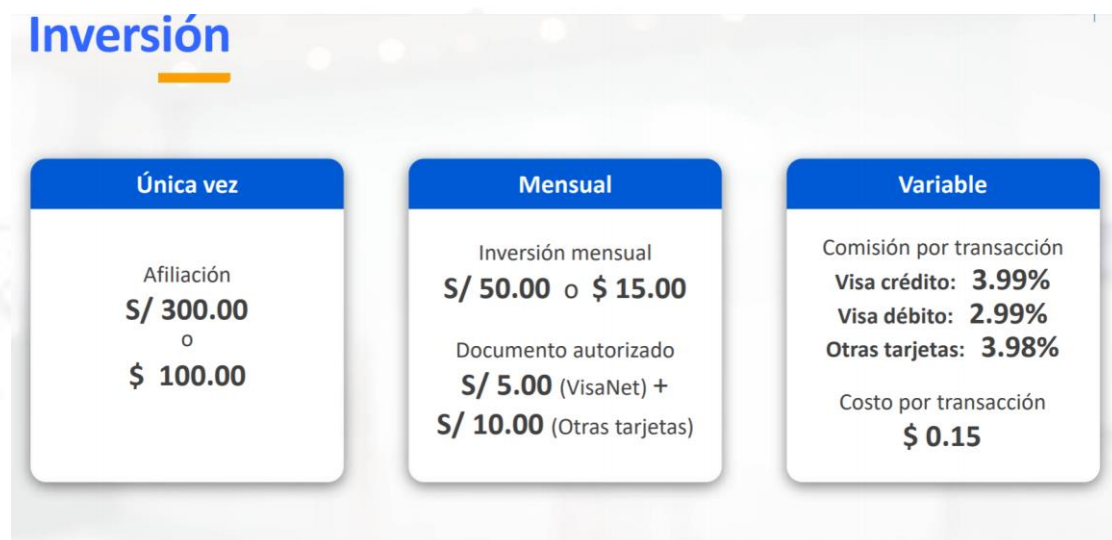
Gastos mensuales	Pago mensual	Pago anual
Gastos operativos por año	S/ 1067	S/ 12804
Suscripción Gitlab (control de versiones) para 4 desarrolladores	S/ 54	S/ 648.00
Compute Engine	S/ 242	S/ 2904,00
Cloud SQL	S/ 175	S/ 2100
Kubernetes Engine	S/246	S/2952
Servidor de correos	S/ 250	S/3000
Gastos Administrativos	S/14000	S/168000
Personal Desarrollo Aplicativo (Front, Back)	S/10000	S/ 120000
Personal Administrativo	S/4000	S/48000
Publicidad Facebook Ads	S/ 1500	S/ 18000
Publicidad medios masivos	S/150	S/1800
Publicidad Instagram Ads	S/ 550	S/ 6600

Fuente: Elaboración propia.

3.2.1.3 Pago a proveedores de servicio

VisaNet cobra por cada transacción \$ 0.15 y una comisión del 3.45% sobre el monto de la transacción. Ver figura 3.4

Figura 3.4 Costo de inversión web



Fuente: Visanet (2019)

Se han considerado como los siguientes supuestos:

- El tipo de cambio del dólar es de S/ 3.365.
- El ticket promedio de la “alquiler directo” será de S/. 150.00
- La proporción de alquiler al año por usuario es de 2 a 1, de cada dos una alquilera.
- Para el pago a VisaNet por “alquiler directo”
 - El valor de “Comisión (S/)” se calcula multiplicando “Número de alquileres directos realizadas” por el ticket promedio correspondiente por 3.45%.
 - El valor de “Comisión transaccional (S/)” se calcula multiplicando “Número de alquileres directas realizadas” por \$0.15 por el tipo de cambio del dólar.
- Para el cálculo no se ha considerado IGV e inflación.
- Un usuario hace una transacción al año

Tabla 6**Detalle de pagos a VisaNet**

		Año 1	Año 2	Año 3	Año 4	Año 5
Pago a VisaNet por "alquiler directo"						
Número de ventas directas realizadas		13,807	23,012	28,765	31,961	35,512
Comisión (S/)	3.45%	71,452.21	119,087.01	148,858.77	165,398.63	183,776.26
Comisión transaccional (S/)	\$0.15	6,969.18	11,615.30	14,519.12	16,132.36	17,924.84
TOTAL, PAGAR VISANET (S/)	A A	78,421.39	130,702.31	163,377.89	181,530.99	201,701.10

Fuente: Elaboración propia.

3.2.1.4 Cálculo de la venta e ingresos proyectada

Según Rpp Noticias. (2018) *“En Lima existen tiendas donde podemos encontrar vestidos de alta gama, con pedrería fina, de seda y que, por un precio cómodo, que oscila entre los 50US\$ a 80US\$ lo podemos llevar a casa y lucirlo en nuestra noche importante.”*

Tabla 7**Detalle de Precios**

Usuario	Periodo	Actividad económica	Ticket promedio	Precio
Persona natural	Año 1	Alquiler	S/150.00	5% comisión
Persona natural	Año 2 – Año 5	Alquiler	S/150.00	10% comisión

Fuente: Elaboración propia.

A continuación, se presenta el resumen de la venta e ingresos proyectada por año, se han considerado los siguientes supuestos:

- El mes de operación no habrá ingresos con la finalidad de generar una base de clientes.
- El alquiler es la actividad donde la persona natural alquila la ropa en cuestión. En el primer año se cobrará una comisión del 5 % y para los siguientes años será del 10 %.
- Se estima tener como usuarios de la plataforma el 4% del mercado potencial (35512)
- Para el primer año se considera de usuarios del 40%, al segundo año un 20% y para el resto de los años 10%.
- El ticket promedio de la “alquiler” será de S/ 150.00.
- Para el cálculo de los ingresos no se ha considerado IGV e inflación

Tabla 8

Ingresos proyectados por año

	Año 1	Año 2	Año 3	Año 4	Año 5
Usuarios por año	13,807	23,012	28,765	31,961	35,512
INGRESOS POR TRANSACCIÓN (S/)	7.5	15	15	15	15
INGRESOS TOTALES (S/)	207,107.85	345,179.75	431,474.69	479,416.32	532,684.80

Fuente: Elaboración propia

3.2.1.5 Flujo de caja

Aquí el detalle final del flujo de caja para los 5 años siguientes en donde se puede observar que a partir del tercer año los flujos futuros se vuelven positivos.

FC	AÑOS						
	0	1	2	3	4	5	
INGRESOS:							
(+)	Personas		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80
(A)	TOTAL INGRESOS		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80
GASTOS:							
(-)	G. ADMINISTRATIVOS		168000	168000	168000	168000	168000
(-)	G. OPERATIVOS		12804	12804	12804	12804	12804
(-)	PAGO VISANET		78,421.39	130,702.31	163,377.89	181,530.99	201,701.10
	TOTAL GASTOS		259,225.39	311,506.31	344,181.89	362,334.99	382,505.10
(-)	IMP. RENTA (30%)				10,102.03	29,218.45	43,889.93
(-)	Gasto Pre Operativo	220654					

(B)	TOTAL EGRESOS	220654	309,392.07	311,506.31	334,079.86	333,116.54	338,615.17
-----	----------------------	--------	------------	------------	------------	------------	------------

(A- B)	FLUJO DE CAJA ECONÓMICO	- 220,654.00	- 102,284.22	33,673.44	97,394.83	146,299.78	194,069.63
	SALDO INICIA		- 128,868.80	- 166,177.98	33,673.44	97,394.83	146,299.78
	Flujo Neto	- 220,654.00	- 231,153.02	- 132,504.54	131,068.27	243,694.61	340,369.41

FC	AÑOS					
	0	1	2	3	4	5

INGRESOS:

(+)	Personas		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80
(A)	TOTAL INGRESOS		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80

GASTOS:

(-)	G. ADMINISTRATIVOS		168000	168000	168000	168000	168000
(-)	G. OPERATIVOS		12804	12804	12804	12804	12804
(-)	PAGO VISANET		78,421.39	130,702.31	163,377.89	181,530.99	201,701.10
	TOTAL GASTOS		259,225.39	311,506.31	344,181.89	362,334.99	382,505.10

(-)	IMP. RENTA (30%)				10,102.03	29,218.45	43,889.93
-----	------------------	--	--	--	-----------	-----------	-----------

(-)	Gasto Pre Operativo	220654					
-----	---------------------	--------	--	--	--	--	--

(B)	TOTAL EGRESOS	220654	309,392.07	311,506.31	334,079.86	333,116.54	338,615.17
-----	----------------------	--------	------------	------------	------------	------------	------------

(A- B)	FLUJO DE CAJA ECONÓMICO	- 220,654.00	- 102,284.22	33,673.44	97,394.83	146,299.78	194,069.63
	SALDO INICIA		- 128,868.80	- 166,177.98	33,673.44	97,394.83	146,299.78
	Flujo Neto	- 220,654.00	- 231,153.02	- 132,504.54	131,068.27	243,694.61	340,369.41

FC	AÑOS					
	0	1	2	3	4	5

INGRESOS:

(+)	Personas		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80
(A)	TOTAL INGRESOS		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80

GASTOS:

(-)	G. ADMINISTRATIVOS		168000	168000	168000	168000	168000
(-)	G. OPERATIVOS		12804	12804	12804	12804	12804
(-)	PAGO VISANET		78,421.39	130,702.31	163,377.89	181,530.99	201,701.10
	TOTAL GASTOS		259,225.39	311,506.31	344,181.89	362,334.99	382,505.10

(-)	IMP. RENTA (30%)				10,102.03	29,218.45	43,889.93
-----	------------------	--	--	--	-----------	-----------	-----------

(-)	Gasto Pre Operativo	220654					
-----	---------------------	--------	--	--	--	--	--

(B)	TOTAL EGRESOS	220654	309,392.07	311,506.31	334,079.86	333,116.54	338,615.17
-----	----------------------	--------	------------	------------	------------	------------	------------

(A- B)	FLUJO DE CAJA ECONÓMICO	- 220,654.00	- 102,284.22	33,673.44	97,394.83	146,299.78	194,069.63
	SALDO INICIA		- 128,868.80	- 166,177.98	33,673.44	97,394.83	146,299.78
	Flujo Neto	- 220,654.00	- 231,153.02	- 132,504.54	131,068.27	243,694.61	340,369.41

FC	AÑOS					
	0	1	2	3	4	5

INGRESOS:

(+)	Personas		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80
(A)	TOTAL INGRESOS		207,107.85	345,179.75	431,474.69	479,416.32	532,684.80

GASTOS:

(-)	G. ADMINISTRATIVOS		168000	168000	168000	168000	168000
(-)	G. OPERATIVOS		12804	12804	12804	12804	12804
(-)	PAGO VISANET		78,421.39	130,702.31	163,377.89	181,530.99	201,701.10
	TOTAL GASTOS		259,225.39	311,506.31	344,181.89	362,334.99	382,505.10

(-)	IMP. RENTA (30%)				10,102.03	29,218.45	43,889.93
(-)	Gasto Pre Operativo	220654					
(B)	TOTAL EGRESOS	220654	309,392.07	311,506.31	334,079.86	333,116.54	338,615.17
(A- B)	FLUJO DE CAJA ECONÓMICO	- 220,654.00	- 102,284.22	33,673.44	97,394.83	146,299.78	194,069.63
	SALDO INICIA		- 128,868.80	- 166,177.98	33,673.44	97,394.83	146,299.78
	Flujo Neto	- 220,654.00	- 231,153.02	- 132,504.54	131,068.27	243,694.61	340,369.41

Por último, se presenta los cálculos de la VAN y TIR:

Tabla 9

Cálculo del VAN y el TIR

VAN	42,648.52
Tasa de retorno de inversión (anual)	7%
TIR	11%

Fuente: Elaboración propia.

En base al análisis del VAN del proyecto se concluye que se llega a generar una ganancia de S/ 42,648.52 y se recupera la inversión. En el cálculo del TIR se concluye que el proyecto genera una rentabilidad mayor a la esperada por los inversores y el proyecto es viable.

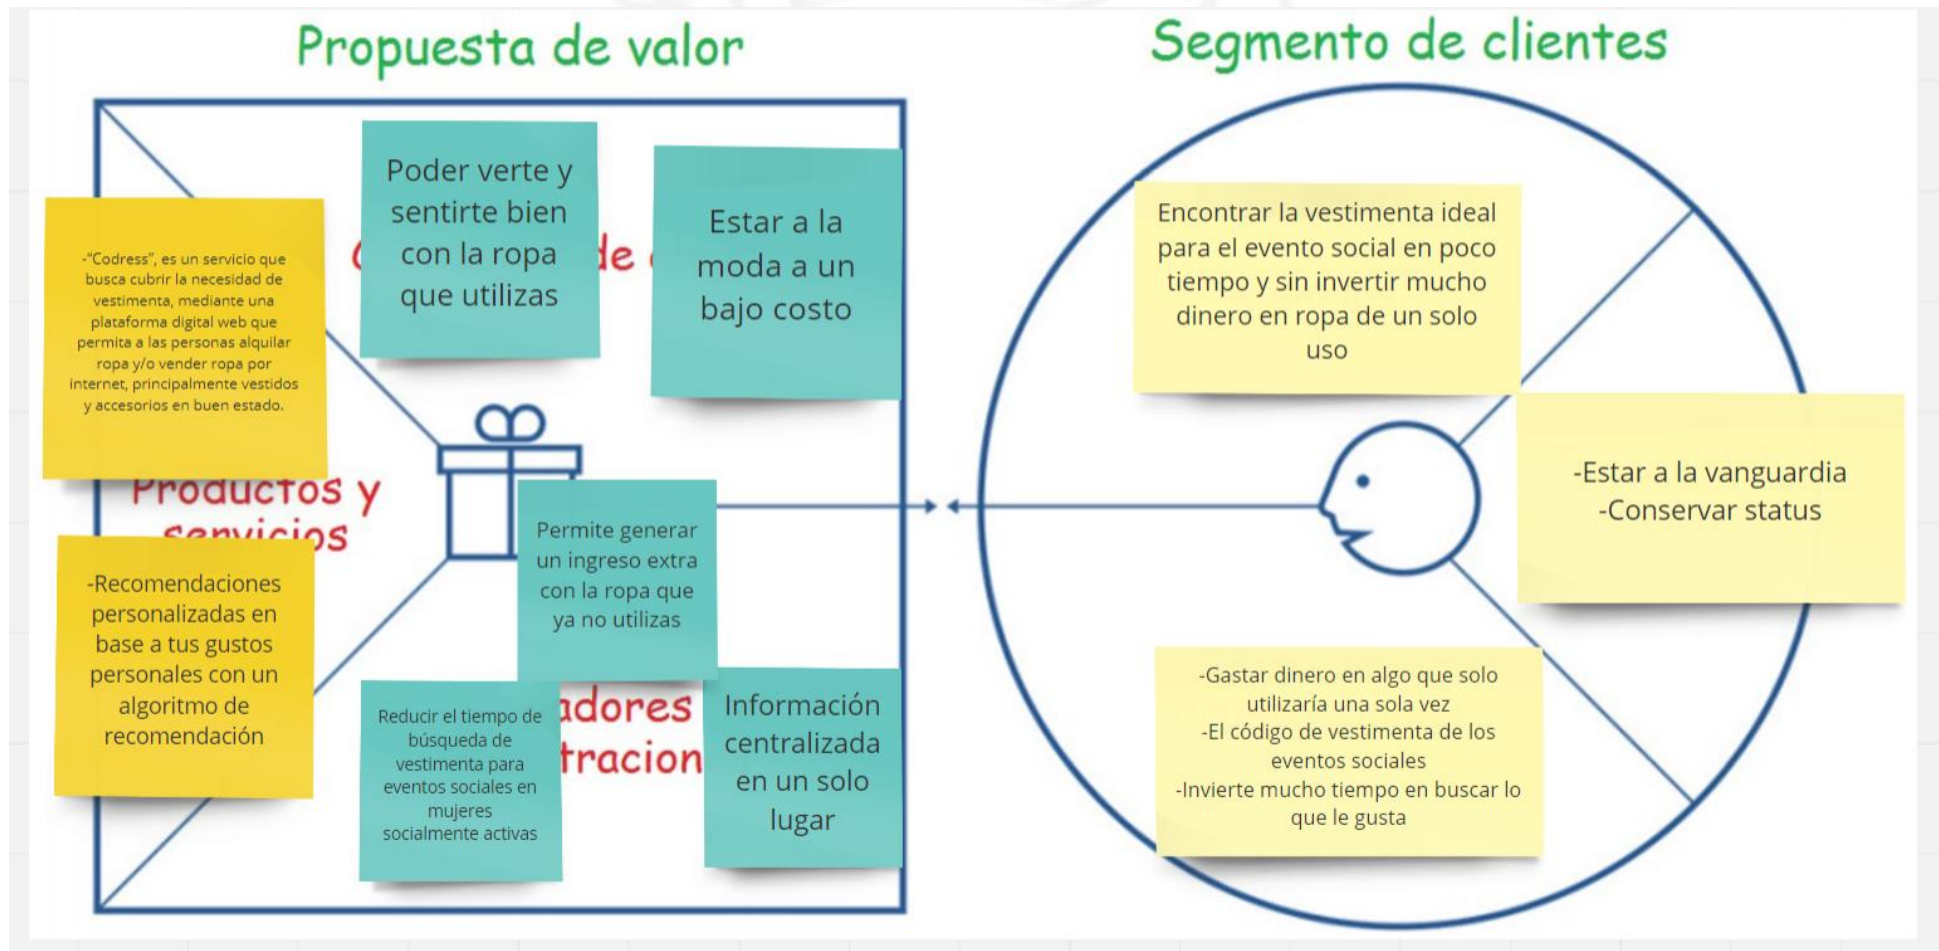
CAPÍTULO IV: DEFINICIÓN DEL PROYECTO

4.1 Diseño de propuesta de valor

Se diseñó la propuesta de valor que cumple con las necesidades de los early adopters en base a las entrevistas, además se definieron las características del segmento de clientes y el mapa de valor, donde se especifica cómo se pretende crear valor con nuestra solución para ellos, así como las funcionalidades que trabajan sobre los pain-points de los usuarios e incluye como se soluciona.

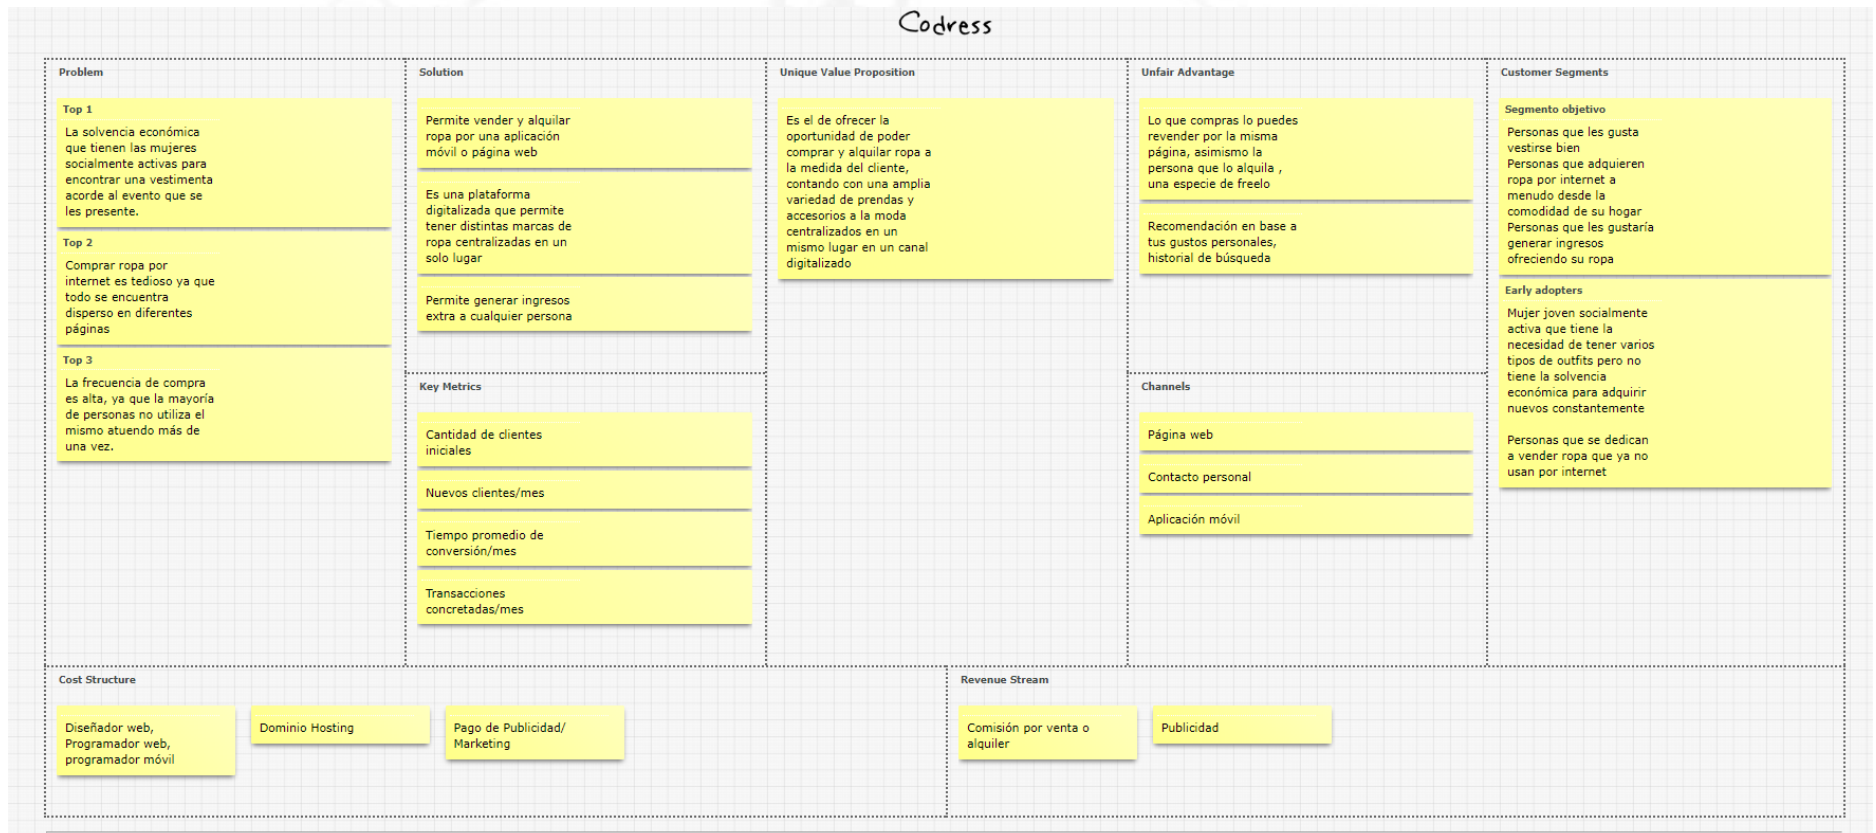


Figura 4.1 Definición de la propuesta de valor



Fuente: Elaboración Propia (2019).

En base a esto se generó la versión del lean canvas en base al modelo de negocio propuesto.



Segmento de mercado

Segmento objetivo

- Clientes:
Mujeres en Lima Metropolitana
Mujeres entre las edades de 20 a 30 años
Mujeres que pertenezcan a los segmentos B y C
Mujeres modernas, que tengan acceso a internet, acostumbradas al uso de la tecnología.
Mujeres socialmente activas que asistan a eventos como matrimonios y requieran vestidos de fiesta.
- Ofertantes:
Personas que residan en Lima metropolitana.
Personas naturales que tienen vestidos de fiesta disponibles y en óptimas condiciones para ser rentados
Personas que deseen alquilar sus vestidos de fiesta y así obtener una ganancia o recuperar la inversión que hicieron previamente.
Personas que tengan acceso a internet.

Early adopters:

- Mujer joven socialmente activa que tiene la necesidad de tener varios tipos de outfits, pero no tiene la solvencia económica para adquirir nuevos constantemente
- Personas que se dedican a vender ropa que ya no usan por internet

Problemas

- La solvencia económica que tienen las mujeres socialmente activas para encontrar una vestimenta acorde al evento que se les presente.
- Comprar ropa por internet es tedioso ya que todo se encuentra disperso en diferentes páginas.
- La frecuencia de compra de vestidos es alta, ya que la mayoría de personas no utiliza el mismo atuendo más de una vez, especialmente vestidos.

(Alternativas a la solución propuesta)

- DRESS2GO: Alquiler de vestidos
- Closket: se presenta como un gran Marketplace en el que comprar y vender ropa de segunda mano.

Este startup, acelerada por Wayra, se diferencia de Chicfy por estructurarse como red social en la que por ejemplo se puede seguir el «armario personal» de cualquier usuario (los conocidos como Closkets) y en que también incluye al público masculino.

- Mona: apuesta por vestidos y ropa de alta calidad que no vende, sino que alquila para eventos especiales, permitiendo que sean las propias usuarias las que pongan en alquiler esos vestidos que ya no se ponen, pero que, además, pueden recuperar cuando los vuelvan a necesitar.
- Nuptialista: aplica la filosofía de segunda mano a los vestidos de novia y en general, a los complementos relacionados con una boda. Se presentan en este sentido como el Marketplace más completo de compra y venta de vestidos de boda on-line: trajes de novia, de madrinas, de invitadas, de boda civil, etc.
- Percentil: representa probablemente el modelo más exitoso de España en el terreno de la venta de ropa de segunda mano. Especializada en la venta de niños y bebés

Propuesta de valor única

Es el de ofrecer la posibilidad alquilar ropa por internet, ahorrando tiempo a las mujeres socialmente activas. Asimismo, se apoya del hecho de que los proveedores del producto pueda ser cualquier persona, además se pretende generar una recomendación de ropa en base a los gustos de cada persona.

Solución

3 características principales del servicio

- Permite alquilar ropa por una página web
- Permite generar recomendaciones de vestimenta en base a gustos personales.
- Permite generar ingresos extra a cualquier persona

Canales

- Página web
- Contacto personal
- Aplicación móvil

Flujos de ingresos

- Comisión por el alquiler de vestidos y accesorios.
- Publicidad de las marcas

Estructura de costos

- Diseñador web, Programador web, programador móvil
- Dominio Hosting
- Administrador y Base de datos
- Pago de Publicidad/ Marketing

Métricas clave

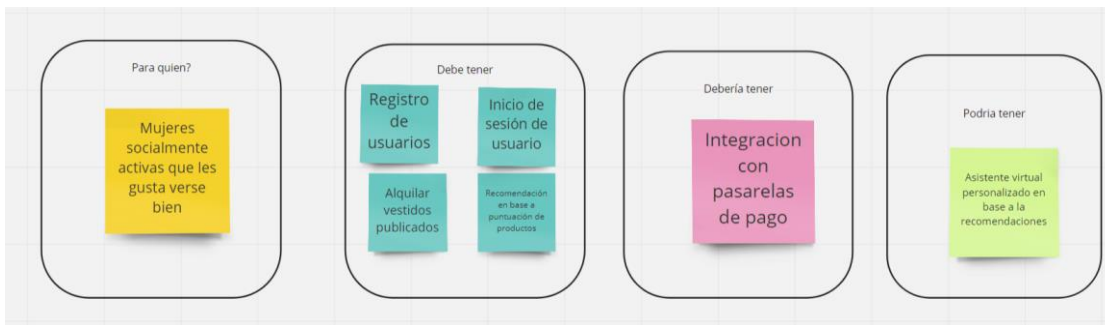
- Cantidad de clientes iniciales
- Nuevos clientes/mes
- Tiempo promedio de conversión/mes
- Descargas app/mes
- Transacciones concretadas/mes

Unfair advantage

- Lo que compras lo puedes revender por la misma página, asimismo la persona que lo alquila, una especie de freelo.
- Recomendación en base a tus gustos personales, historial de búsqueda.

A partir de ello se definió el mínimo producto viable (MVP) y las funcionalidades que debe tener, que debería tener y que podría tener como se visualiza en la siguiente imagen.

Figura 4.2 Definición del MVP de Codress



Fuente: Elaboración Propia (2019).

4.2 Objetivos generales y específicos

4.2.1 Objetivo general

- Diseñar una plataforma digital de alquiler de ropa integrado a un sistema de recomendación que permita descubrir los gustos de los usuarios, mejorando su experiencia y satisfacción.

4.2.2 Objetivos específicos

- Aplicar la metodología Design Thinking para encontrar los gustos y preferencias del público objetivo.
- Desarrollo de la plataforma digital
- Integración de los gustos personales en la plataforma con el algoritmo de filtrado de recomendación.

4.2.3 Modelo de negocio propuesto

4.2.3.1 Modelo de negocio

El objetivo de este modelo de negocio es describir que Codress puede resolver y aliviar los problemas descritos anteriormente ofreciendo un valor agregado al cliente de manera efectiva con las siguientes características:

- Novedad:

Se ha identificado la necesidad de satisfacer la vanidad del común de las mujeres de contar con un vestido diferente para cada ocasión. El hecho de que se pueda elegir un vestido desde vía web, ahorrando tiempo a las usuarias; también convierte la idea en novedosa. Por otro lado, el hecho de que los proveedores del producto pueda ser cualquier persona natural (que tenga un vestido en óptimas condiciones para alquilarlo o venderlo) también resulta ser una idea innovadora, pues podría resultar que el vestido deseado lo tenga alguien que reside muy cerca y le ahorraría tiempo a la usuaria en salir a buscar.

- Precio y Mercado:

El precio inicial para las personas ofertantes de la plataforma que quieran subir sus productos será gratuito, luego se cobrará una comisión de intermediación por transacción.

También se tiene pensado generar alianzas estratégicas con empresas de lavandería para garantizar los estándares de sanidad de los productos ofertados en la plataforma, empresas como Mr Jeff.

- Diseño:

La aplicación tendrá un diseño amigable, simple y ayudará a las usuarias a elegir lo más conveniente para cada ocasión.

- Comodidad/Utilidad:

El servicio planteado es una herramienta que facilita la búsqueda de vestidos para determinadas ocasiones, con lo que no será necesario salir de casa.

- Estrategia:

La estrategia consiste en utilizar la tecnología y la innovación tecnológica como principal factor en el desarrollo de una plataforma digital. Finalmente, la misma recomendará productos en base a los gustos personales de los usuarios.

- Alcance

En el corto plazo (primer año)

Implementación de la página web de cara a los usuarios para poder alquilar ropa por internet principalmente vestidos.

A mediano plazo (a partir del segundo año)

Mejorar la precisión en las recomendaciones del algoritmo en base a la data de de adquisición de ropa de los usuarios y de los productos ofertados por los mismos.

Visión a largo plazo

Generar una plataforma referente en este rubro, con alcance a nivel mundial donde cualquiera persona pueda alquilar su ropa y generar un ingreso extra (internacionalización).

4.2.4 Roles de equipo de proyecto

Tabla 10

Roles de proyecto

Rol	Nombre	Responsabilidades
CEO	Diego Renteria	Liderar el desarrollo de la estrategia de la empresa
Programador Backend/FrontEnd	Diego Renteria Por definir	Encargados de convertir las especificaciones utilizando lenguajes de programación, así como herramientas de software de apoyo a la programación y de análisis de data
Diseñador y UX	Por definir	El encargado de generar el diseño de la plataforma e interacción de la misma.

Fuente: Elaboración Propia (2019)

4.2.5 Stack Tecnológico

En el desarrollo planteado para el MVP del proyecto se tendrá todo desplegado en el Serverless de google, específicamente Firebase.

Pero, ¿qué podemos hacer con Firebase?

Con firebase podemos, por ejemplo:

- Lograr una integración dinámica de los usuarios usando el componente Firebase Authentication.
- Lograr que nuestras aplicaciones sean visualizadas y utilizadas utilizando la herramienta de compartir o Dynamic Links
- Enviar notificaciones push a varias plataformas con Cloud Messaging
- Crear análisis de resultados con Analytics

Para el desarrollo se requiere de tres principales componentes: Firestore, Authentication y Cloud Functions.

Donde, según la documentación de Google (2020):

- **Firestore:** es una base de datos flexible y escalable para la programación en servidores, dispositivos móviles y la Web desde Firebase y Google Cloud Platform. Al igual que Firebase Realtime Database, mantiene tus datos sincronizados entre apps cliente a través de agentes de escucha en tiempo real y ofrece asistencia sin conexión para dispositivos móviles y la Web, por lo que puedes compilar apps con capacidad de respuesta que funcionan sin importar la latencia de la red ni la conectividad a Internet. **(vale decir es una base de datos en tiempo real)**
- **Authentication:** Firebase Authentication proporciona servicios de backend, SDK fáciles de usar y bibliotecas de IU ya elaboradas para autenticar a los usuarios en tu app. Admite la autenticación mediante contraseñas, números de teléfono, proveedores de identidad federada populares, **como Google, Facebook y Twitter, y mucho más.**
- Firebase Authentication se integra estrechamente en otros servicios de Firebase y aprovecha los estándares de la industria como OAuth 2.0 y

OpenID Connect, por lo que se puede integrar fácilmente con tu backend personalizado.

- Cloud Functions: permite ejecutar automáticamente el código de backend en respuesta a eventos activados por las funciones de Firebase y las solicitudes HTTPS. Tu código se almacena en la nube de Google y se ejecuta en un entorno administrado. No necesitas administrar ni escalar tus propios servidores.

Valores (en dólar) de Firebase

Firebase, en principio, te da la opción de comenzar por un plan gratuito y luego, acceder a uno pago. El plan sin cargos se llama “Spark”.

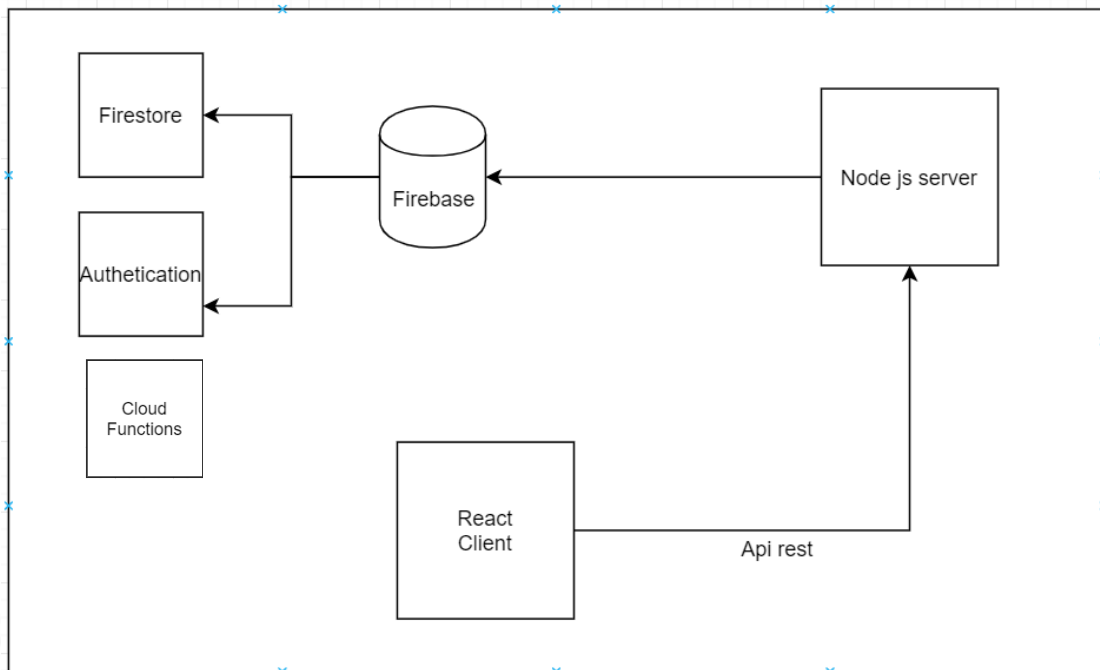
Los planes con costo son:

- Plan Flame, el cual, tiene precio fijo para las aplicaciones en expansión por USD \$25 por mes.
- Plan Blaze, tiene una calculadora de precios que estima los gastos mensuales del plan.

Es así, como Firebase se adapta al uso que le vayas a dar al mismo. Comenzando con plan gratuito se tendría desarrollado en poco tiempo.

Como se observa en la figura 4.3, se tiene firebase de la nube, utilizando los componentes descritos para almacenar los productos, registrar usuarios. La comunicación se daría mediante un servidor node js, y todo sería consumido por api rest desde un frontend desarrollado (que sería la web) con el framework de javascript React.

Figura 4.3 Diagrama de Infraestructura de aplicación para el MVP



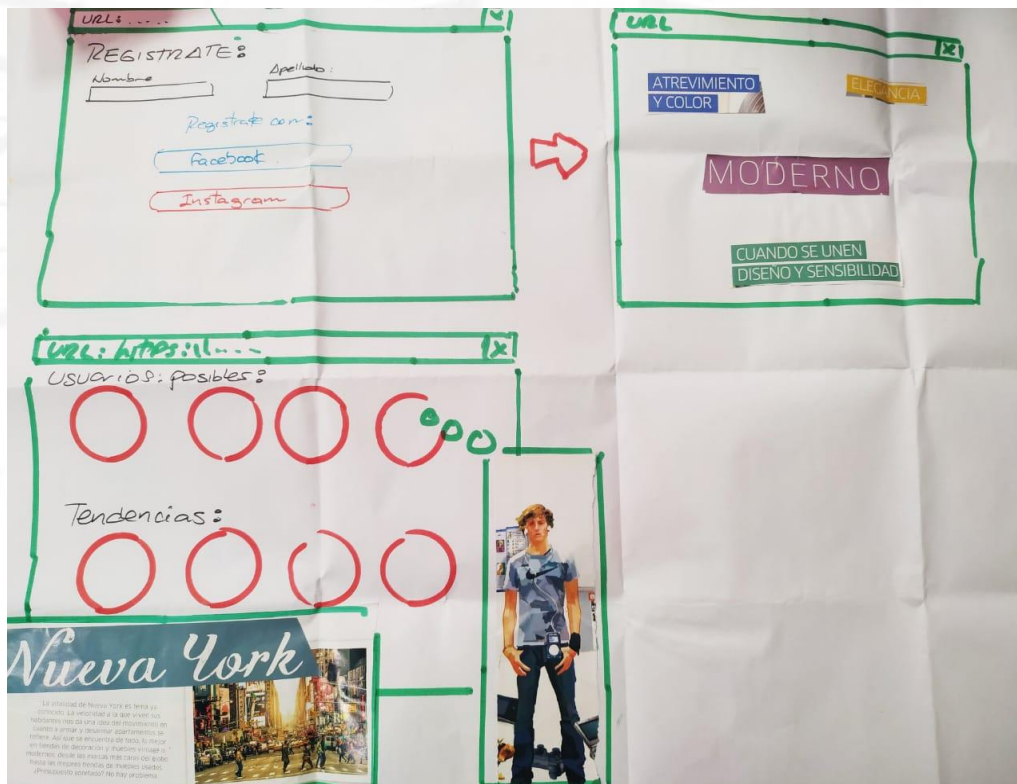
Fuente: Elaboración Propia (2019)

CAPÍTULO V: DESARROLLO DEL PROTOTIPO

5.1 Prototipado

En esta etapa se realizó la creación del prototipo luego de la definición de lo que el producto debería tener realizado en el paso de ideación. La aplicación permite a los usuarios publicar ropa por internet para que otras personas puedan alquilar, y en la medida irá recolectando data para mejorar la precisión del algoritmo de recomendación planteado.

Figura 5.1 Prototipo a mano alzada



Fuente: Elaboración Propia (2019)

5.1.1 Mvp

Cabe recalcar que para el desarrollo del Mvp, no se tienen definidas todas las variables idóneas en la definición del modelo de recomendación, se ha intentado considerar todas

las posibles variables como tal que son influyentes en los productos ofrecidos y de los usuarios de la plataforma.

El sistema de recomendación que se plantea como solución se basa en el viaje de un nuevo cliente desde el momento en que llega a la plataforma por primera vez hasta que realiza compras repetidas.

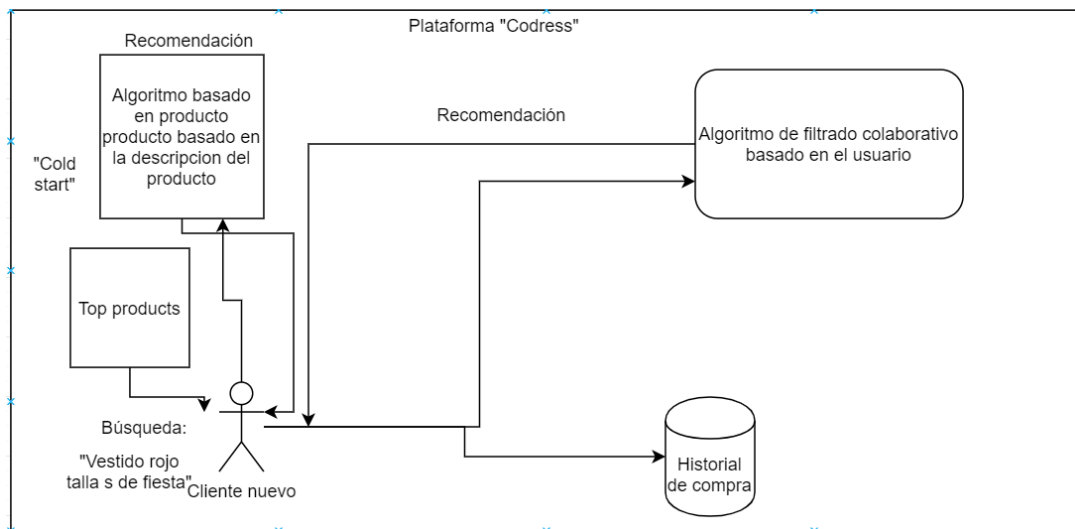
Dicho de otro modo, cuando un nuevo cliente sin ningún historial de compras anterior visita la plataforma por primera vez, se le recomiendan los tops productos más populares vendidos. Una vez que realiza un alquiler en este caso, el sistema de recomendaciones se actualiza y recomienda otros productos en función del historial de compras y las calificaciones proporcionadas por otros usuarios (vecindad).

Vale decir se define en dos partes:

La primera parte será utilizando un algoritmo híbrido (basado en artículo a artículo basado en la descripción del producto), quiere decir que por cada producto subido a la plataforma se plantea con la descripción del mismo definir pequeños clusters (“grupos), para así plantear un buscador que juegue con las palabras claves del usuario al interactuar con la plataforma como punto de partida, ya que inicialmente no se tiene recomendación. Para armar esta descripción se van a usar variables como la talla, el tipo de prenda, el color, la marca, el tipo de evento, ya que en primera instancia se puede inferir que si la descripción no es suficiente se puede no lograr lo esperado. Por ejemplo, una blusa de fiesta es diferente a una de noche; además hay marcas más deseables como un Dior frente a un Sybila.

La segunda parte se utilizará el algoritmo de filtrado colaborativo basado en usuario con la data de compra recolectada en consecuencia de las compras realizadas por el usuario de la parte 1 y rating de los usuarios a los productos con gustos similares. En este punto nos podríamos preguntar como abarcar otro problema que tienen los algoritmos de filtrado colaborativo, que es lo que pasa cuando aparece un nuevo usuario en el vecindario, para esto se ha definido como parte de esta implementación utilizar la técnica del “top product”, que básicamente es buscar el producto más popular en el sistema y utilizarlo como punto de partida de recomendación al nuevo usuario.

Figura 5.2 Diagrama de bloques de la propuesta



Fuente: Elaboración propia

Como se definió en la sección donde se explican los conceptos y fundamentos de la solución, la implementación del algoritmo como tal para este proyecto se va a dar en dos partes. Para ello se utilizará el lenguaje de programación Python y Jupiter Notebook (que es un entorno interactivo web de ejecución de código para python).

- Algoritmo híbrido (basado en artículo a artículo basado en la descripción del producto)

Variables a utilizar para definir al producto

Variable	Ejemplo
Talla	XS, S, M, L
Tipo de evento	Fiesta, casual.
Marca	Sybila, Guess, Dior, etc.
Color	Rojo, Verde.
Tipo de prenda	Vestido, blusa
Precio	100, 150 soles
Calidad	Nuevo, usado

Variable para armar la descripción del producto para el algoritmo en base a las variables del producto.

product_uid	product_description
0001	Vestido rojo de fiesta marca guess talla small

Donde:

product_uid: Id único autogenerated del producto

product_description: descripción contextual detallada del producto en cuestión

Variables a utilizar para definir al usuario

Variable	
Nivel de ingresos	Alto, Medio y Bajo
Distrito	Miraflores, San Borja, La Molina.
Edad	Entre 20 y 30 años
Sexo	Masculino/ Femenino
Origen	Local, Turista.
Estilo de vida	Sofisticada, Moderna, Conservadora.
Ocupación	Dependiente, Independiente.

Se importan las librerías a utilizar (TfidfVectorizer, CountVectorizer, NearestNeighbors, KMeans y adjust_rand_score)

```
desde sklearn.feature_extraction.text importar TfidfVectorizer,  
CountVectorizer  
desde sklearn.neighbors importar NearestNeighbors  
desde sklearn.cluster importar KMeans  
desde sklearn.metrics importat adjusted_rand_score
```

Se lee la data almacenada de los productos con sus descripciones en formato csv y se almacena en una variable

```
product_descriptions = pd.read_csv('codress_descriptions.csv')
```

Se convierte el texto de la descripción de los productos en data numérica para su análisis

```
vectorizer = TfidfVectorizer(stop_words=español)
X1 = vectorizer.fit_transform(product_descriptions["product_description"])
X1
```

Palabras principales en cada grupo según la descripción del producto

```
true_k = 10
model = KMeans(n_clusters=true_k, init='k-means++', max_iter=100,
n_init=1)
model.fit(X1)
imprimir("Top terminos por cluster:")
order_centroids = model.cluster_centers_.argsort()[:, :-1]
terminos = vectorizer.get_feature_names()
repetir i en range(true_k):
    imprimir("Cluster %d:" % i),
    repetir ind en order_centroids[i, :10]:
        imprimit(' %s' % terminos [ind]),
    imprimir
```

Finalmente en base a como se agruparon los productos en cada cluster se podría hacer una predicción en base la búsqueda dada del usuario y sus atributos como tal, con la siguiente formula

```
imprimir("Cluster ID:")
Y = vectorizer.transform(["vestido rojo talla s"])
prediction = model.predict(Y)
imprimir(prediction)
```

Se obtiene por ejemplo que este vestido rojo se encuentra en el Cluster con ID 9.

- **Algoritmo de filtrado colaborativo basado en usuario (historial de compra)**

#Variables a utilizar

UserId	ProductId	Rating	TimeStamp
C34201832	00311	4.0	1329699100

C94901832	00001	5.0	1369699200
-----------	-------	-----	------------

Donde:

UserId: Id único autogenerado por usuario.

ProductId: Id del producto que el usuario evalúa.

Rating: ponderación del 1 al 5 del producto que le da el usuario.

TimeStamp: Momento en que se da la recomendación.

Se importan las librerías a utilizar (numpy, panda y matplotlib.pyplot)

NumPy: es una extensión de Python, que le agrega mayor soporte para vectores y matrices, constituyendo una biblioteca de funciones matemáticas de alto nivel para operar con esos vectores o matrices.

Panda: es un paquete de Python que proporciona estructuras de datos similares a los dataframes de R. Pandas depende de Numpy, la librería que añade un potente tipo matricial a Python.

matplotlib.pyplot: es un paquete de Python para generar gráficos.

Sklearn: es una biblioteca para aprendizaje de máquina de software libre para el lenguaje de programación Python

```
importar numpy como "np"  
importar pandas como "pd"  
importar matplotlib.pyplot como "plt"  
# %matplotlib inline  
plt.style.use("ggplot")  
importar sklearn  
desde sklearn.decomposition importar TruncatedSVD
```

Cargando el dataset almacenado en format csv

```
codress_ratings = pd.read_csv('ratings_Codress.csv')
```

CASO ESPECIAL: En el caso de un usuario Nuevo del cual no se tiene ninguna interacción de compra y rating con la plataforma, se podría ir con la implementación del algoritmo híbrido descrito en la parte 1 o de otra forma recomendarle los 10 productos más populares como punto de

entrada al ingresar a la plataforma en base a su búsqueda dada y sus atributos que lo identifican como cliente.

```
popular_products  
pd.DataFrame(codress_ratings.groupby('ProductId')['Rating'].count())  
most_popular = popular_products.sort_values('Rating', ascending=False)
```

Se define la matriz de utilidad (consiste en todos los detalles posibles de preferencias (clasificaciones) de elementos de usuario representados como una matriz. La matriz de utilidad es escasa ya que ninguno de los usuarios compraría todos los elementos de la lista, por lo tanto, la mayoría de los valores son desconocidos).

```
ratings_utility_matrix = amazon_ratings1.pivot_table(values='Rating',  
index='UserId', columns='ProductId', fill_value=0)  
ratings_utility_matrix.head()
```

Se traspone la matriz

```
X = ratings_utility_matrix.T
```

#Se descompone la matriz

```
SVD = TruncatedSVD(n_components=10) decomposed_matrix =  
SVD.fit_transform(X) decomposed_matrix.shape
```

Se obtiene la matriz de correlación

```
correlation_matrix = np.corrcoef(decomposed_matrix)  
correlation_matrix.shape
```

Por ejemplo digamos que un usuario compra el producto con ID # 100

Se obtiene el índice

```
i = "100"
```

```
product_names = list(X.index)
```

```
product_ID = product_names.index(i)
```

```
product_ID
```

#Se obtiene la correlación para todos los artículos con el artículo comprado por este cliente en función de los artículos calificados por otros clientes que compraron el mismo producto

```
correlation_product_ID = correlation_matrix[product_ID]
correlation_product_ID.shape
```

A modo de ejemplo se podría recomendar los 10 productos altamente correlacionados en secuencia

```
Recommend = list(X.index[correlation_product_ID > 0.90])
```

Se quita los ítems que el cliente adquirió

```
Recommend.remove(i)
```

5.1.2 Testeo

5.1.2.1 User Test

La presentación del producto mínimo viable a los potenciales usuarios se realizó en papel en esta primera etapa. Las características de las interacciones y resultados obtenidos se muestran a continuación:

Interacción 1:

- Números de personas con las que se probó el MVP: 12
 - Mujeres entre 18 y 30 años: 12
- Cambios o mejoras solicitadas por los potenciales usuarios/clientes:
 - Mujeres entre 18 y 30 años:
 - Mejorar el diseño de la plataforma.
 - Poder ver el feedback de las personas que hayan decidido alquilar para mejorar su poder de decisión de compra.
 - Poder dar feedback de los productos publicados, subir productos y ver mis recomendaciones
- Modificaciones aceptadas de la interacción 1:
 - Se agrega al módulo de productos.
 - Mejorar el diseño de la plataforma.
 - Se agrega la posibilidad de ratear los productos (esto ayudara al algoritmo de filtrado colaborativo ya que permite encontrar la similitud entre dos personas).

Interacción 2:

- Números de personas con las que se probó el MVP: 6

Mujeres entre 18 y 30 años: 12


- Cambios o mejoras solicitadas por los potenciales usuarios/clientes:
 - Por Mujeres entre 18 y 30 años: 12:
 - Login con redes sociales.
 - Opción de subir productos con imágenes, gestionar sus productos.
 - Integración con pasarelas de pago al ser una especie de ecommerce.
 - Ver mis recomendaciones de ropa en base a mi historial de puntuaciones y búsqueda (similitud con otros usuarios).

5.1.2.2 Rediseño de Prototipo

Los diseños finales de la página web para el MPV definido incluyen:

Página de Bienvenida (home)

Vista general de inicio de la web donde se muestran las categorías de los productos ofrecidos



Fuente: Elaboración Propia (2019)

Página de Registro

Esta vista permite al usuario acceder y registrar su cuenta en Codress con su perfil y de tal forma poder subir la ropa a alquilar. Los errores serán informados en la parte superior del campo de usuario, de tal forma el usuario final será informado acerca de los problemas ocurridos en el proceso de validación de identidad contra Codress.

Formulario de Registro y Login

Ya tengo una cuenta

Ingresar con tu email y password

No tengo una cuenta

Ingresar con tu email y password

Fuente: Elaboración Propia (2019)

Vestidos con su puntuación (rating)

The screenshot shows the Codress website interface. At the top left is the logo 'Codress'. To the right are navigation links: TIENDA, INGRESAR, PRODUCTO, RECOMENDACION, and a shopping bag icon. Below the navigation is the heading 'Mujeres'. The main content area displays a grid of four clothing items, each with a product image, name, price, seller name, and a star rating:

- Blue Tanktop**: Price 25, Seller Diego Renteria, Rating 4 stars.
- Floral Blouse**: Price 20, Seller Alessandra Renteria, Rating 4 stars.
- Floral Dress**: Price 80, Seller Diego Renteria, Rating 4 stars.
- Red Dots Dress**: Price 80, Seller Diandra Sanchez, Rating 4 stars.

Below the grid are three smaller, partially visible product images.

Fuente: Elaboración Propia (2019)

En esta vista se puede elegir los vestidos de elección a alquilar y ponerlos en la bolsa como una página de ecomerce.

This screenshot is similar to the previous one, but it includes a shopping cart overlay on the right side of the grid. The cart contains the following items:



- Blue Tanktop 1 x S/25
- Floral Dress 1 x S/80

At the bottom of the cart overlay is a black button with the text 'IR A ALQUILAR'.

Fuente: Elaboración propia

Luego se procede a ver el detalle del monto total a pagar por los productos seleccionados.

Codress TIENDA INGRESAR PRODUCTO RECOMENDACION

Producto	Descripcion	Cantidad	Precio	Eliminar
	Blue Tanktop	< 1 >	25	×
	Floral Dress	< 1 >	80	×

TOTAL: S/105

Fuente: Elaboración propia

Floral Dress 80 ×

Codress
Tu total es 105

diegalonso.renteria@gmail.c ×

Envío Facturación

Diego Alonso Renteria

jr 2# 293 dpto 202 monterric

Lima 4142

Peru

Detalles de pago +

TOTAL: S/105

by stripe

Pagar

Fuente: Elaboración propia

Finalmente se procede a pagar mediante la integración de la web con la pasarela de pago, en este caso se visualiza como ejemplo los detalles del cliente y su dirección (esta sería la vista reflejada de visa para poner los datos de la tarjeta).

CONCLUSIONES

- El flujo de caja indica que Codress en cuestión es económicamente viable, en base a que se obtienen utilidades positivas con los supuestos.
- Asimismo, con base a los elementos tecnológicos y de procesos necesarios para la operatividad planteada, se infiere que el proceso que requiere el mayor esfuerzo en cuanto a inversión monetaria es el correcto funcionamiento de la plataforma digital ya que este es el medio por el cual se ofrecerá el servicio de alquiler que es el pilar definido para la operación de la empresa.
- El incremento en el uso de la tecnología por la población peruana muestra un escenario favorable para el desarrollo de la propuesta, sumado al boom del crecimiento del ecommerce y la digitalización de la población.
- La metodología aplicada en este proyecto de innovación Design Thinking permiten a las empresas y emprendimientos validar un producto o servicio de manera rápida y aun bajo costo, a través de la experimentación del cliente con el producto, conocer a tu cliente, muy utilizado en este tiempo.

RECOMENDACIONES

A continuación, detallaremos las recomendaciones:

- Dado que en la actualidad las personas están interconectadas y compran por internet a través del celular es necesario investigar y determinar todos los procesos y costos para desarrollar un aplicativo móvil en el futuro, integrado con un algoritmo de recomendación que podría generar un mayor alcance de mercado.
- La integración de la plataforma con Visanet en el estudio financiero representa una cantidad de dinero alta, por lo cual se debe determinar a través un análisis si para la aplicación en cuestión es primordial tener este tipo de integración para lograr una mayor rentabilidad.
- Luego que se tenga una cantidad de datos significativo se debe tratar de aplicar más variables para mejorar la precisión del modelo.

GLOSARIO DE TÉRMINOS

Tabla 11

Diccionario de los términos especializados empleados en el proyecto.

TERMINO	SIGNIFICADO
Back-End	Capa de procesamiento de los datos de la aplicación con los sistemas de soporte
Framework	Marco de trabajo para el desarrollo
Front-End	Capa de presentación al usuario final
MVP	Acrónimo de Minimum Viable Product
TIR	Acrónimo de Tasa Interna de Retorno
UX	Acrónimo de User Experience
VAN	Acrónimo de Valor Actual Neto
Wireframe/Mockup	Se refiere a un esquema de página o plano de pantalla, es una guía visual que representa la estructura visual de un sitio web

REFERENCIAS

- Burke, R. (2002). Interactive critiquing for catalog navigation in e-commerce. *Artificial Intelligence Review*, 18(3-4), 245-267.
- Gestión. (2018). Un limeño pierde en promedio 20 días al año atrapado en el tráfico | RPP Noticias. Recuperado del sitio de internet <https://rpp.pe/peru/actualidad/un-limeno-pierde-en-promedio-20-dias-al-ano-atrapado-en-el-trafico-noticia-1146916>
- Gestión. (2019). "Cyber days: ¿Cómo han evolucionado las compras virtuales de los peruanos?" Recuperado del sitio de internet <https://gestion.pe/economia/cyber-days-han-evolucionado-compras-virtuales-peruanos-273132-noticia/>
- Gómez, P., Guarda, T., Cedeño, J., Benavides, A., Alejandro, C., Mosquera, G., ... & Benavides, V. (2019). Sistemas de Recomendación: un enfoque a las técnicas de filtrado. *Revista Ibérica de Sistemas e Tecnologías de Información*, (E18), 286-293.
- Santa-Olalla, B. (2018). Design thinking aplicado al storytelling. Recuperado del sitio de Internet. <https://innovacionaudiovisual.com/2018/01/19/design-thinking-aplicado-al-storytelling/>
- Medium. (2018). Introduction To Recommendation system In Javascript. Recuperado del sitio de internet: <https://becominghuman.ai/introduction-to-recommendation-system-in-javascript-74209c7ff2f7>
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques*. San Francisco, CA, itd: Morgan Kaufmann. Recuperado del sitio de internet. <https://doi.org/10.1016/B978-0-12-381479-1.00001-0>
- Fabra, U. P. (2004). *Sistemas de recomendaciones: herramientas para el filtrado de información en Internet*. Recuperado del sitio de Internet <https://www.upf.edu/hipertextnet/numero-2/recomendacion.html>
- Linio. (2019). Índice mundial de comercio electrónico. Recuperado del sitio de Internet <https://www.linio.com.pe/sp/indice-ecommerce>
- Visanet(2019). Pago Web. Recuperado del sitio de internet <https://www.visanet.com.pe/mundovisanet/admin/assets/documentos/5df1d2dbc4fafc49316456d0475e80e7.pdf>
- Rpp Noticias. (2018). Tendencias | El boom del alquiler de vestidos en Lima . Recuperado del sitio de Internet <https://rpp.pe/blog/atrevete-y-usalo/tendencias-el-boom-del-alquiler-de-vestidos-en-lima-noticia-1097697>

Parra, Denis (2017). Tipos de RS: Filtrado Colaborativo – Sistemas de Recomendación.
Recuperado del sitio de Internet <https://recommendersys.wordpress.com/2017/10/20/tipos-de-rs-filtrado-colaborativo/>



BIBLIOGRAFÍA



ANEXOS



Anexo 1 Guía de Entrevista

Hipótesis: Mujer socialmente activa con la necesidad de encontrar un vestido para una ocasión especial, que cuente con poco tiempo y tenga como opción poder alquilar un vestido.

Presentación

Buenos días/tardes mi nombre es **Diego Alonso Renteria Vidaurre**, actualmente me encuentro en un proceso de titulación por la modalidad de proyecto de innovación, y estoy realizando una investigación para conocer un poco más sobre ti y quisiera comenzar por agradecer por el tiempo brindado y la información obtenida. Así mismo valoro mucho tu opinión honesta. Si no estás seguro sobre algo o no quieres responder a cualquier pregunta, por favor no dudes en comentarme para pasar al siguiente punto.

Primero, déjame contarte un poco sobre mí, como ya te había comentado mi nombre es Diego, estudie la carrera de sistemas y me desempeño actualmente como Programador FullStack en la fintech Kambista y llegué aquí (se cuenta historia personal).

Ahora cuéntame un poco sobre ti exactamente ¿Quiero entender lo que te motiva?, Estamos aquí para divertirnos, por eso no hay respuestas buenas ni malas ¡Todo vale!

Validando al entorno (Entrevistas): Preguntas propuestas

1. ¿En eventos como fiestas, sueles usar vestidos?
2. Cuéntame tu experiencia. ¿De qué forma consigues tus vestidos?, ¿Dónde buscas?, ¿Alquilas o compras?, ¿Cuánto tiempo demoras usualmente para tu elección?
3. ¿Con qué frecuencia tienes estos eventos en los cuales deseas verte bien?
4. ¿Has comprado ropa por internet? ¿Cuéntame tu experiencia? ¿Cómo mejorarías dicha experiencia?
5. ¿Qué es lo que más valoras en tus compras y/o alquileres? Por ejemplo: diseño, moda, precio.
6. ¿Qué opinas de los precios que vienes pagando para conseguir tus vestidos?
7. ¿Tienes preferencias por algunas marcas o tiendas? ¿Qué tan importante es para ti usar una marca reconocida para un evento?

8. Si contemplas la opción de alquilar vestidos, ¿bajo qué condiciones lo harías?
¿Cuánto estarías dispuesta a pagar por un alquiler?
9. ¿Cuánto gastaste la última vez en un vestido para un evento importante?
10. Si te dijera que estoy desarrollando una plataforma digital de alquiler de vestidos nuevos y/o usados, en el que además podrías tener recomendaciones personalizadas en base a tus gustos personales ¿Lo utilizarías?
 - o Definitivamente lo usaría.
 - o Es muy poco probable que lo utilice.
 - o Es medianamente probable que lo utilice.
 - o Muy poco probable que lo utilice.
 - o No lo usaría

Interesadas en dar en alquiler

1. Has prestado alguna vez tu ropa a una amiga o familiar. ¿En qué ocasiones?
2. Si contemplas la opción de dar en alquiler tus vestidos, ¿bajo qué condiciones lo harías? ¿Cuánto estarías dispuesta a cobrar por un alquiler?
3. Si te dijera que puedes vender o alquilar tu ropa mediante una plataforma digital ¿Lo utilizarías?
 - o Definitivamente lo usaría
 - o Es muy poco probable que lo utilice.
 - o Es medianamente probable que lo utilice.
 - o Muy poco probable que lo utilice.
 - o No lo usaría.
4. ¿Cuánto te gustaría recibir por venta y cuanto por alquiler?