

Propuesta de Métricas de Usuario para Definir Perfiles de Usuario

Proposal of User Metrics to Define User Profiles

Alberto GasparDepartament d'informàtica
Escola Tècnica Superior
d'EnginyeriaUniversitat de València,
Avenida de la universidad s/n,
46100 Burjasot, España
alberto.gaspar@uv.es**José Ignacio Panach**Departament d'informàtica
Escola Tècnica Superior
d'EnginyeriaUniversitat de València,
Avenida de la universidad s/n,
46100 Burjasot, España
joigpana@uv.es**Miriam Gil**Departament d'informàtica
Escola Tècnica Superior
d'EnginyeriaUniversitat de València,
Avenida de la universidad s/n,
46100 Burjasot, España
miriam.gil@uv.es**Verónica Romero**Departament d'informàtica
Escola Tècnica Superior
d'EnginyeriaUniversitat de València,
Avenida de la universidad s/n,
46100 Burjasot, España
veronica.romero@uv.es

Recibido: 10.03.2025 | Aceptado: 20.05.2025

DOI: <https://doi.org/10.65234/interaccion.124>

Palabras Clave

Perfil de usuario

Métricas de usuario

Características de usuario

Adaptación

Resumen

La adaptación en tiempo de ejecución de los elementos gráficos de la interfaz de usuario es fundamental en el desarrollo de interfaces inteligentes. Para lograrlo, el sistema debe identificar las características del usuario de manera precisa y no intrusiva, permitiendo establecer su perfil y garantizando una interacción más cómoda y segura. Este trabajo propone métricas para recopilar información del usuario y definir perfiles en tiempo de ejecución, basadas en un modelo previamente establecido. Las métricas, extraídas de investigaciones previas, han sido clasificadas en automáticas y manuales según si sus parámetros pueden obtenerse en tiempo real. Como contribución, se han definido los parámetros necesarios para estimar las características clave de cada métrica. Además, se presenta un caso práctico para ilustrar su funcionamiento y un experimento con usuarios reales para evaluar su grado de coincidencia con los resultados esperados por los sujetos. Este estudio representa un avance hacia una metodología para diseñar sistemas interfaces de usuario inteligentes capaces de ajustarse dinámicamente al comportamiento y acciones del usuario en tiempo de ejecución.

Keywords

User profile

User metrics

User characteristics

Adaptation

Abstract

The real-time adaptation of graphical elements in the user interface is essential for the development of intelligent interfaces. To achieve this, the system must identify user characteristics in a precise and non-intrusive manner, allowing for the establishment of a user profile and ensuring a more comfortable and secure interaction. This study proposes metrics for collecting user information and defining profiles in real-time, based on a previously established model. The metrics, derived from previous research, have been classified as either automatic or manual, depending on whether their parameters can be obtained in real-time. As a contribution, the necessary parameters have been defined to estimate the key characteristics of each metric. Additionally, a practical case study is presented to illustrate its functionality, along with an experiment involving real users to assess the degree of alignment between their results and the expected outcomes. This study represents progress towards a methodology for designing intelligent user interfaces capable of dynamically adjusting to user behavior and actions in real-time.

1. Introducción

Las interfaces de usuario inteligentes (IUI) establecen una serie de reglas y comportamientos para adaptar los elementos de la

interfaz gráfica a las diferentes características de los usuarios. Para lograr esto, es necesario comprender cómo interactúan los usuarios con los sistemas y diseñar interfaces de usuario

adaptables (Schmidt et al., 2021). Uno de los aspectos más importantes a la hora de implementar una IUI es establecer cómo extraer las características del usuario. Para ello, estos sistemas implementan un conjunto de métricas de usuario. Una métrica de usuario se define como una medida diseñada para analizar las características del usuario durante su interacción con el sistema, con el fin de identificar sus preferencias y las configuraciones esperadas (Hou et al., 2021). La información obtenida de estas métricas de usuario permite al sistema definir su perfil de usuario. El perfil de usuario se define como el conjunto virtual de los datos y configuraciones personales que permite identificar a los usuarios en el sistema y da la posibilidad de analizar y visualizar el tipo de usuarios que interactúan con el sistema (Wu et al., 2024).

Adaptar la interfaz de usuario específicamente a las características de cada perfil de usuario es un proceso muy complejo porque sería necesario crear una interfaz específica para cada perfil de usuario. Para solucionarlo, es necesario definir un conjunto de grupos diferenciados de perfiles de usuario que agrupen a los usuarios en función de sus características comunes, de forma que el sistema pueda adaptarse a cada grupo de perfiles de usuario (Abri et al., 2020). Por ejemplo, en un comercio electrónico cuando la métrica de usuario detecta que el usuario se encuentra en un país donde se paga en euros, el sistema puede definir diferentes grupos de perfil de usuario en función de la opción de pago y mostrar el precio del producto en euros.

Automatizar el proceso de extracción de características de usuario es un proceso complejo de implementar, pero aporta una serie de beneficios, como la reducción del tiempo en recoger la información del usuario y adaptar las interfaces en tiempo real. La automatización permite aumentar la precisión de los valores obtenidos ya que de esta manera el sistema evita considerar posibles errores humanos que el usuario realice cuando rellene los formularios, como puede ser poner mal su ubicación. Por último, esta automatización permite a los sistemas adaptarse en tiempo de ejecución a los diferentes cambios que tengan las características de los usuarios puesto que permite actualizar la información del usuario en cada interacción con el sistema (Hu et al., 2020; Ziosi et al., 2024).

Para extraer el perfil del usuario, es necesario definir las características de usuario. Para ello, previamente, hemos publicado un modelo de usuario que contiene las características de usuario necesarias para poder definir a los usuarios que interactúan con el sistema. Las métricas presentadas en este artículo buscan obtener las características necesarias para rellenar este modelo de usuario (Gaspar et al., 2024).

La principal contribución de este estudio es la presentación de un conjunto de métricas de usuario diseñadas para extraer las características necesarias que permitan una implementación efectiva del perfil de usuario, el cual se almacena en el modelo

correspondiente. Estas métricas han sido seleccionadas a partir de investigaciones previas. No obstante, un problema recurrente en dichos estudios es la ausencia de especificación sobre los parámetros concretos para calcular el valor de estas métricas. Nuestra contribución no solo radica en la identificación de las métricas a partir de la literatura existente, sino también en la definición de los parámetros necesarios para su cálculo. Las métricas identificadas se han clasificado en dos categorías: métricas automáticas, que el sistema puede recopilar sin intervención del usuario, y métricas manuales, que requieren que el usuario introduzca sus valores. Se busca priorizar el uso de métricas automáticas para minimizar la necesidad de interacción del usuario. Además, se ha implementado un proceso de validación para evaluar los resultados obtenidos con las métricas propuestas en comparación con los valores esperados por los usuarios.

Esta contribución se enmarca en un proyecto más ambicioso donde se plantea como próximos pasos definir los diferentes grupos de perfiles de usuario, definir las reglas a seguir para clasificar a los usuarios en cada grupo de perfil de usuario e implementar los comportamientos necesarios para adaptar los componentes de la Interfaz Gráfica de Usuario (IGU).

El artículo está estructurado de la siguiente manera. En la sección 2 se presentan una serie de trabajos previos. La sección 3 presenta las diferentes métricas de usuario definidas, clasificándolas en métricas manuales y métricas automáticas. La sección 4 presenta un ejemplo de sistema que hace uso de las métricas. La sección 5 define la fase experimental de las métricas de usuario propuestas. La sección 6 presenta los resultados y la discusión de los resultados obtenidos. Finalmente, la sección 7 presenta las diferentes conclusiones y trabajo futuro.

2. Estado del arte

La extracción de perfiles de usuario desempeña un papel activo en diversos dominios como el desarrollo de videojuegos, los sistemas de recomendación, o el comercio electrónico. En todos estos dominios se han llevado a cabo trabajos centrados en la obtención de las características de los usuarios de la forma más automática posible y en superar las dificultades existentes.

Definir métricas de usuario presenta una serie de retos. Algunos retos están relacionados con el uso de técnicas de aprendizaje automático. La complejidad computacional necesaria para definir cada una de las métricas de usuario y el tiempo necesario para definir estas métricas son considerados los retos más importantes. Dicha complejidad computacional viene dada por el alto volumen y variedad de información necesaria para que los algoritmos recojan y clasifiquen correctamente dicha información, en este caso, las características de los usuarios (Tufail et al., 2023). Otro reto

derivado de esto consiste en determinar los falsos positivos y negativos. En otras palabras, determinar cuándo una clasificación errónea de una característica de usuario se debe a un mal entrenamiento del algoritmo y cuándo se debe a un diseño incorrecto de la métrica (Singh, 2022). La privacidad de los datos de los usuarios se trata de un reto, porque los usuarios maliciosos tratarán de acceder a las características de usuario alojadas en el servidor. Además, la información necesaria para clasificar a los usuarios y el intercambio de información que se produce entre el servidor y la interfaz de usuario puede provocar una brecha de seguridad importante que permita acceder a las características recopiladas por el sistema a usuarios no autorizados (Gilbert et al., 2023).

Existen diferentes técnicas de inteligencia artificial utilizadas en el modelado del comportamiento del usuario y en la construcción de perfiles eficientes y eficaces. Entre estas técnicas destacan los modelos de soporte vectorial, los modelos de Markov o, más recientemente, las redes neuronales. Sin embargo, cada método de elaboración de perfiles de usuario tiene su propia forma de procesar la información, lo que crea una heterogeneidad que no favorece la evaluación comparativa de estas técnicas. Recientemente se han presentado trabajos que intentan estandarizar la entrada necesaria en este tipo de sistemas. FairUp (Abdelrazek et al., 2023), presenta un marco que estandariza la entrada de un sistema basado en Redes Neuronales Gráficas (GNN) para tareas de creación de perfiles de usuario.

En el campo de los videojuegos, conocer el perfil del usuario es fundamental para adaptar la dificultad del juego a sus habilidades, evitando, de esta forma, la frustración y el aburrimiento de éste. Sepulveda et al. (2020), investiga la metodología Dynamic Difficult Adjustment (DDA). Esta metodología almacena de forma dinámica las habilidades y conocimientos de los usuarios a partir del número de acciones realizadas para establecer el nivel de dificultad correspondiente a estas habilidades, mejorando la usabilidad del videojuego y el compromiso del usuario.

Los perfiles de usuario desempeñan un papel fundamental en los sistemas de recomendación. Estos perfiles de usuario son claves para capturar las preferencias de los usuarios, con el fin de personalizar las recomendaciones, o llevar a cabo un filtrado colaborativo, donde se utilizan perfiles similares para recomendar elementos apreciados por usuarios similares. En la literatura encontramos múltiples trabajos de definición de perfiles de usuario en este tipo de sistemas. Un ejemplo se encuentra en el método Dynamic User Interest Print (D-UIP) (Alhijawi et al., 2023) que almacena de forma dinámica las preferencias del usuario.

Los trabajos descritos en esta sección presentan diferentes metodologías para adaptarse a los usuarios. Sin embargo, estos trabajos, no aportan los parámetros concretos para definir las

métricas empleadas. Nuestra propuesta integra este conjunto de métricas de usuario, estableciendo la forma en la que se calculan a partir de los parámetros.

3. Definición de las métricas de usuario

Este proyecto se desarrolló entre agosto y diciembre de 2023 e involucró a un equipo compuesto por cuatro estudiantes de la carrera de Ciencias de la Computación de una universidad privada ubicada en Brasil. El proyecto está integrado en la asignatura de Interacción Persona-Computador, que utilizó el Aprendizaje Basado en Problemas (ABP) para impartir tanto el contenido teórico como la parte práctica de la asignatura. De este modo, se presentará cómo se desarrolló la asignatura, así como el proyecto de desarrollo del juego enfocado en abordar temas relacionados con el medio ambiente.

La principal aportación de este trabajo consiste en la definición de un conjunto de métricas que se encargan de recopilar las características del usuario para permitir que las interfaces se adapten en tiempo de ejecución al usuario. Para definir estas métricas, se ha realizado un estudio de la literatura previa siguiendo el método de búsqueda de bibliografía específica llamado “Target Literature Review” (TLR) (Mangat & Sharma, 2023), que comprueba en una primera búsqueda si el resumen, las palabras clave o el título contienen alguna de las siguientes cadenas: (“user metrics” AND “intelligent user interface”) OR (“detect user characteristics” AND “human-computer interaction”). Además de la cadena de búsqueda, se aplican criterios de inclusión y exclusión para filtrar artículos. Los criterios de inclusión fueron los siguientes: (IC1) las métricas de usuario incluyen una descripción precisa de su fórmula y de sus parámetros; (IC2) dichas métricas de usuario han sido validadas con usuarios. Los criterios de exclusión fueron los siguientes: (EC1) las métricas de usuario expuestas no tienen aplicación directa en la extracción de las características de usuario, (EC2) las métricas de usuario no incluyen una validación. Primero se hizo una búsqueda en las librerías digitales Scopus y ACM digital library, aplicando los criterios de inclusión y exclusión al resumen, palabras clave, y título. El resultado devolvió 50 referencias. Después se aplicaron los mismos criterios a la lectura completa de cada artículo, reduciendo las referencias a 35.

Como conclusión del TLR, se han extraído una serie de métricas de usuario que requieren definir los parámetros a partir de los cuales se calcula su valor. Como contribución de este trabajo, vamos a definir estos parámetros. Si los parámetros se pueden calcular automáticamente a partir de la interacción con el usuario, la métrica será de tipo **automática**. Si existen parámetros que dependan de valores introducidos explícitamente por el usuario, la métrica será de tipo **manual**. A continuación, se definen los dos tipos de métricas con los parámetros necesarios para calcularlas.

3.1 Métricas automáticas

Estas métricas recopilan características del usuario de forma no intrusiva mientras el usuario interactúa con el sistema. Cada una de las características de usuario expresadas en el modelo de usuario (Gaspar et al., 2024) se obtienen de una o varias métricas. Cuando se usa más de una métrica por característica, el sistema procede a realizar el promedio de los valores de cada métrica para definir el valor de la característica.

La característica **conocimiento** trata de definir la capacidad del usuario para que el sistema pueda ajustar el nivel de complejidad de las respuestas al conocimiento del usuario (Salem & Al-Saedi, 2023). La tabla 1 muestra el conjunto de métricas propuestas para extraer el conocimiento del usuario y su rango de valores. En la columna Rango se incluye para cada posible valor, el peso que se asigna a ese rango a la hora de calcular la media que define la característica. Por ejemplo, cuando C_u vale 1, el peso es 1. Esta característica depende del promedio de varias métricas. La métrica C_u (Wang & Liu, 2023) realiza la resta absoluta entre el número de clics del usuario y los clics estimados para completar la tarea. La métrica D_v (Zhou et al., 2021) realiza la resta absoluta entre el desplazamiento vertical (scroll) realizado por el usuario y el estimado. La métrica N_b (Zhou et al., 2021) obtiene el número de búsquedas que ha realizado el usuario. La métrica P (Yu et al., 2018) consiste en realizar la resta absoluta entre los clics del usuario y las opciones accedidas por el usuario. De esta forma se obtienen los clics en los que el usuario no ha seleccionado ninguna opción. La métrica T_t (Yu et al., 2018) se basa en realizar la resta absoluta entre el tiempo que ha necesitado el usuario para completar la tarea y el estimado. La métrica T_p (Yu et al., 2021) consiste en obtener un valor medio de tiempo que el usuario interactúa con cada página. La métrica P_s (Yu et al., 2018) se basa en contar los periodos de inactividad del usuario que son superiores a 5 segundos. La métrica Com (Rao et al., 2020) comprueba si el usuario ha realizado correctamente la tarea y C_q (Wang & Liu, 2023) indica la complejidad de las consultas realizadas para completar la tarea. Una vez calculado el promedio de todas estas métricas, el sistema determina si un usuario posee *conocimientos altos* sobre el sistema (promedio superior a 0.80); si posee *conocimientos medios* (promedio entre 0.50 y 0.79); o si posee *conocimientos bajos* (promedio menor a 0.50).

Tabla 1 Métricas y rangos para extraer los conocimientos del usuario

Métrica	Rango
$C_u = \text{clics}_{\text{usuario}} - \text{clics}_{\text{estimados}} $ (Wang & Liu, 2023)	$C_u = 1; 1$ $1 < C_u \leq 3; .5$ $C_u > 3; 0$
$D_v = Des_{\text{usuario}} - Des_{\text{estimado}} $ (Zhou et al., 2021)	$D_v \leq 50; 1$ $50 < D_v \leq 200; .5$ $D_v > 200; 0$
$N_b = \sum(\text{clicks en search})$ (Zhou et al., 2021)	$N_b \leq 2; 1$ $2 < N_b \leq 5; .5$ $N_b > 5; 0$
$P = \text{clics}_{\text{usuario}} - \text{opciones accedidas} $ (Yu et al., 2018)	$P = 0; 1$ $0 < P \leq 2; .5$ $P > 2; 0$
$T_t = \text{TiempoU} - \text{estimado} $ (Yu et al., 2018)	$T_t \leq 10; 1$ $10 < T_t \leq 35; .5$ $T_t > 35; 0$
$T_p = \frac{\text{Tiempo}_{\text{total}}}{\text{Páginas}}$ (Yu et al., 2021)	$T_p \leq 10; 1$ $10 < T_p \leq 20; .5$ $T_p > 20; 0$
$P_s = \sum(\text{inactividad} > 5 \text{ s})$ (Yu et al., 2018)	$P_s = 0; 1$ $0 < P_s \leq 3; .5$ $P_s > 3; 0$
$Com = \zeta \text{ Completa acción?}$ (Rao et al., 2020)	$Com = Si; 1$ $Com = No; 0$
$C_q = \text{complejidad de la query}$ (Wang & Liu, 2023)	$C_q = \text{Alta}; 1$ $C_q = \text{Media}; .5$ $C_q = \text{Baja}; 0$

Tabla 2 Métricas y rangos para extraer las habilidades del usuario

Métrica	Rango
$Co = C_{uo} - opciones_{formulario} $ (Yu et al., 2018)	$Co = 0; 1$ $0 < Co \leq 2; .5$ $Co < 2; 0$
$Ae = \#(acciones\ especiales)$ (Paulino et al., 2024)	$Ae = 1; 1$ $1 < Ae \leq .7; .5$ $Ae < .7; 0$
$P = clics\ usuario - opciones\ accedidas $ (Yu et al., 2018)	$P = 0; 1$ $0 < P \leq 2; .5$ $P > 2; 0$
$Com = ¿Completa\ tarea?$ (Rao et al., 2020)	$Com = Si; 1$ $Com = No; 0$
$Tt = tiempoU - estimado $ (Yu et al., 2018)	$Tt \leq 10; 1$ $10 < Tt \leq 15; .5$ $Tt > 15; 0$
$R = clics_{usuario} - opciones_{sistema} $ (Yu et al., 2021)	$R < 2; 1$ $2 \leq R \leq 5; .5$ $R > 5; 00$

La característica **habilidades** trata de definir la capacidad del usuario para interactuar correctamente con el sistema (Kubanyi et al., 2018). La tabla 2 muestra el conjunto de métricas propuestas para extraer las habilidades del usuario y su rango de valores. Esta característica depende del promedio de varias métricas. La métrica *Co* (Yu et al., 2018) realiza la resta absoluta de los clics del usuario del usuario en las diferentes opciones y las opciones totales presentes en la tarea para saber cuáles de los clics del usuario son errores (no ha pulsado ninguna opción). La métrica *Ae* (Paulino et al., 2024) consiste en realizar el promedio de las acciones especiales del usuario (como puede ser usar atajos del teclado o menús de búsqueda avanzada). La métrica *P* (Yu et al., 2018) se basa en realizar la resta absoluta entre los clics del usuario y las opciones accedidas por el usuario de forma que así se obtienen los clics en los que el usuario no ha seleccionado ninguna opción. La métrica *Com* (Rao et al., 2020) comprueba si el usuario ha podido completar correctamente la tarea. La métrica *Tt* (Yu

et al., 2018) realiza la resta absoluta entre el tiempo que ha necesitado el usuario para completar la tarea y el estimado. La métrica *R* (Yu et al., 2021) consiste en realizar la resta absoluta entre los clics del usuario en opciones y las opciones existentes en la tarea (para saber cuáles clics son en opciones ya visitadas). Una vez calculado el promedio de estas métricas, el sistema determina si el usuario es *experto* (promedio superior a 0.80); *intermedio* (promedio entre 0.50 y 0.79) o *novato* (promedio menor a 0.50).

La característica **objetivos** trata de definir las diferentes causas que llevan al usuario a interactuar con el sistema y qué es lo que espera encontrar en el sistema. Esta característica depende del promedio de varias métricas. La tabla 3 muestra el conjunto de métricas propuestas para extraer los objetivos del usuario y su rango de valores. La métrica *Nb* (Zhou et al., 2021) obtiene el número de búsquedas realizadas por el usuario. La métrica *Odc* (Berkovitch et al., 2024) consiste en comprobar el número de opciones distintas a las que el usuario accede por cada consulta. La métrica *Tmp* (Yu et al., 2021) obtiene el tiempo medio que el usuario está interactuando con cada opción. La métrica *Or* (Yu et al., 2021) se basa en realizar la resta absoluta entre el total de opciones accedidas por el usuario y el número de opciones estimadas para completar la tarea. De esta forma se obtiene el número de opciones diferentes a las que accede el usuario. La métrica *TMPag* (Yu et al., 2021) calcula el tiempo máximo que el usuario ha interactuado con una opción específica. La métrica *Com* (Rao et al., 2020) comprueba si el usuario ha realizado todos los pasos necesarios para completar una acción específica del usuario y *Cq* (Wang & Liu, 2023) calcula la complejidad de las diferentes consultas de texto realizadas. El valor final de esta característica se calcula como el promedio entre todas las métricas. Según la literatura (Shi & Trusov, 2021), hay 3 tipos de objetivos: *Informacional* (promedio inferior a 0.50), el usuario está realizando muchas búsquedas poco completas, visita muchas páginas y está poco tiempo en cada página; *Navegacional* (promedio entre 0.50 y 0.80), el usuario está buscando una funcionalidad o página específica del sistema, realizará pocas búsquedas con consultas complejas, estará mucho tiempo en cada página pero no completa los pasos necesarios para finalizar ninguna acción específica; *Transaccional* (promedio superior a 0.80), en este caso el usuario realizará las mismas acciones que una búsqueda navegacional pero completará la acción específica.

La característica **dispositivo** trata de definir el tipo de hardware que usa el usuario para interactuar con el sistema. Esta característica solo tiene una métrica para determinar el dispositivo del usuario mediante el sistema operativo (Laor et al., 2022). Las opciones son *ordenador de sobremesa* o *portátil*, *Tablet*, *móvil*, *dispositivo inteligente* o desde otro tipo de dispositivo.

La característica **idioma** trata de definir el lenguaje óptimo para comunicarse con el usuario. Está compuesta de dos métricas. La primera consiste en analizar la configuración del idioma del sistema operativo (Gothe et al., 2021). La segunda métrica consiste en analizar el idioma de configuración del teclado. En el caso de que los valores obtenidos por las métricas coinciden, el sistema almacena ese idioma como el idioma del usuario (Gothe et al., 2021). En el caso de no coincidir, el sistema preguntará al usuario cuál de los idiomas detectados prefiere.

Tabla 3 Métricas y rangos para extraer los objetivos del usuario

Métrica	Rango
$Nb = \sum(\text{clics en search})$ (Zhou et al., 2021)	$Nb \leq 2; 1$ $2 < Nb \leq 5; .5$ $Nb > 5; 0$
$Odc = \frac{\text{opciones}_{\text{accedidas}}}{\text{consultas}}$ (Berkovitch et al., 2024)	$Odc \leq 2; 1$ $2 < Odc \leq 5; .5$ $Odc > 5; 0$
$Tmp = \frac{\text{Tiempo total}}{N_{\text{pags_visitadas}}}$ (Yu et al., 2021)	$Tmp \geq 20; 1$ $20 > Tmp \leq 5; .5$ $Tm > 5; 0$
$Or = \text{opciones}_{\text{accedidas}} - \text{diferentes opciones}_{\text{accedidas}} $ (Yu et al., 2021)	$Or < 2; 1$ $2 \leq Or \leq 5; .5$ $Or > 5; 0$
$T_{mpag} = \text{MAX}(\text{tiempo_pagina})$ (Yu et al., 2021)	$T_{mpag} \geq 40; 1$ $40 > T_{mpag} \leq 25; .5$ $T_{mpag} > 25; 0$
$Com = i \text{ Completa acción?}$ (Rao et al., 2020)	$Com = Si; 1$ $Com = No; 0$
$Cq = \text{complejidad de la query}$ (Wang & Liu, 2023)	$Cq = Alta; 1$ $Cq = Media; .5$ $Cq = Baja; 0$

La característica **nacionalidad** trata de definir la ubicación de procedencia del usuario, aunque también se puede valorar la ubicación actual. Esta característica es necesaria porque existen ciertos comportamientos del usuario relacionados con su nacionalidad, como por ejemplo el tipo de divisa que esperan los usuarios en un comercio electrónico. La característica depende de dos métricas. La primera de ellas consiste en obtener la ubicación actual mediante GPS (Jarwal et al., 2022). La segunda de estas métricas consiste en obtener la nacionalidad mediante la IP con la que se conecta al servidor (Mishra et al., 2020). En el caso de que los valores de las dos métricas coincidan el sistema indicará dicha nacionalidad en el perfil del usuario. En el caso de los valores obtenidos por las métricas no coincidan el sistema preguntará al usuario cuál prefiere.

La característica **discapacidades** busca identificar las distintas limitaciones del usuario para interactuar correctamente con el sistema (Kinjo & Mbaitiga, 2022). Esta característica se compone de dos métricas. La primera consiste en analizar los diferentes periféricos para verificar si algunos están destinados a personas con discapacidades (Chang et al., 2020). La segunda métrica analiza la configuración del usuario en el dispositivo para elementos de accesibilidad, como puede ser que el sistema lea todos los textos del navegador en el caso de un usuario invidente (Šumak et al., 2023). La combinación de ambas métricas identifica el conjunto de discapacidades del usuario.

La característica **contexto** trata de definir la situación actual del usuario, es decir, si el usuario se encuentra solo o acompañado, si está realizando alguna otra tarea o por el contrario está concentrado en interactuar con el sistema (Iqbal et al., 2021). La métrica propuesta para esta característica consiste en el uso de diferentes sensores del dispositivo. Estos valores tratan de aprender si el usuario está en movimiento, solo, o acompañado, si puede comunicarse con el dispositivo mediante el habla o por comandos, si está al aire libre o en su casa (Sajana et al., 2022; Sikder et al., 2020).

La característica **intereses** trata de definir los diferentes gustos y preferencias que puede tener el usuario a la hora de buscar productos o servicios en un sistema. Por ejemplo, si un usuario tiene interés en los deportes va a buscar páginas que más información o productos deportivos le ofrezca (Dumitrescu & Santini, 2021). Esta característica depende de dos métricas. La primera consiste en analizar los diferentes tipos de páginas u opciones del sistema a las que accede el usuario (Hoi & Que, 2024). La segunda consiste en registrar si el usuario accede a las recomendaciones del sistema. La combinación de ambas métricas representa el listado de intereses del usuario (Dumitrescu & Santini, 2021).

La característica **emociones** trata de definir las diferentes sensaciones que el usuario experimenta mientras interactúa con el sistema. Esta característica se basa en la métrica propuesta

por Machová et al. (2023), donde se analizan diferentes movimientos del usuario, sus expresiones faciales y su voz para poder determinar su estado emocional en función de las 6 emociones principales (Tristeza, Alegría, Miedo, Sorpresa, Ira, Miedo).

3.2 Métricas manuales

A pesar del esfuerzo por encontrar métricas que se puedan automatizar, existen ciertas características de usuario cuyas métricas dependen de la información que proporcione el propio usuario mediante formularios. A continuación, detallamos estas características.

Las características **edad y género** pretenden determinar ciertos comportamientos. Sun et al. (2020) ponen como ejemplo un estudio en el que se visualiza que los usuarios masculinos buscaban libros de ciencia ficción mientras que los femeninos buscaban libros que les ayudasen a mejorar su estilo de vida. Además, existen ciertos sistemas en los que la clasificación del género de los usuarios es vital para adaptarse correctamente a ellos, como puede ser un comercio electrónico de ropa. Conocer el rango de edad de los usuarios es un aspecto importante porque hay acciones o productos que están limitados a cierta edad de los usuarios, bien porque están prohibidos a usuarios que no lleguen a la edad específica, como por ejemplo para crear una red social es necesario tener más de 18 años, o porque el producto está recomendado a un rango de edad específico de usuarios (Rybczewska & Sparks, 2022).

Las características **trabajo, perfil y experiencia laborales** son también relevantes según los trabajos de Jin et al. (2020). Por ejemplo, un usuario considerado experto en su trabajo posee unos conocimientos muy altos en dicho ámbito y esperará unas respuestas más técnicas y elaboradas en comparación con un usuario con poca experiencia.

La característica **nivel de estudios** del usuario engloba los posibles conocimientos que el usuario haya podido adquirir con la finalidad de poder ajustar la tecnicidad de la información (Hawamdeh et al., 2022). La característica **preferencias** del usuario engloba ciertos elementos gráficos que el usuario debe elegir explícitamente, como puede ser el tema deseado para visualizar el sistema o el tamaño de fuente (Vandic et al., 2024).

La característica **salario** está relacionada con el posible presupuesto que puede tener el usuario para realizar compras o suscripciones en el sistema (Oukfif et al., 2020). Aunque existen aplicaciones que usan la ubicación del usuario para determinar el presupuesto, como hacen ciertos sistemas de suscripciones como *Netflix*, *YouTube* o *Twitch*, consideramos que el salario del usuario también influye a la hora de suscribirse a estos sistemas (Oukfif et al., 2020). Para ello, consideramos que el sistema debe contener una opción en las

mismas preferencias de usuario en el que el usuario puede seleccionar el precio mínimo y máximo.

La característica **aficiones** consiste en registrar las acciones que el usuario está realizando en su tiempo libre, como puede ser jugar a videojuegos o escuchar música. Esta característica permite ofrecer respuestas relacionadas con esos pasatiempos (Sandoval-Gaytan et al., 2023).

4. Ejemplo práctico de uso de métricas de usuario propuestas

En esta sección se va a mostrar un ejemplo de uso de estas métricas de usuario. Para ello, se va a definir un sistema de recomendación de videos, similar a YouTube, que ilustra cómo se recopilan las características del usuario a través de las métricas. De las 7 tareas definidas en este escenario, las 2 primeras tareas se encargan de obtener las métricas manuales, mientras que las 4 tareas restantes se encargan de obtener las métricas automáticas.

- Tarea 1: El usuario rellena el formulario de registro y se obtendrán las siguientes características: edad, género, trabajo, perfil laboral, experiencia laboral, discapacidades, aficiones, nivel de estudios.
- Tarea 2: El usuario establece sus preferencias respecto al idioma y nacionalidad. La característica que se define es preferencias, idioma, la nacionalidad y el dispositivo.
- Tarea 3: El usuario debe buscar un video de un canal en concreto y de una temática de ocio, mientras que el sistema automáticamente se recopila las habilidades y objetivos del usuario.
- Tarea 4: El usuario debe indicar de un conjunto de videos seleccionados cuál describe mejor el término “interfaz inteligente de usuario”, mientras que el sistema determina sus objetivos.
- Tarea 5: El usuario debe verificar y, en caso necesario, modificar, los valores obtenidos por los sensores de proximidad, de movimiento, micrófono y webcam mientras el sistema detecta automáticamente el contexto del usuario.
- Tarea 6: El usuario debe configurar un recordatorio en la aplicación para que le muestre una alerta cuando su cantante preferido publique una nueva canción. El sistema evalúa automáticamente los conocimientos del usuario.
- Tarea 7: El usuario debe elegir el video que más le interese de un listado de la portada, mientras el

sistema automáticamente registra los posibles intereses del usuario.

A continuación, se va a describir a la protopersona utilizada para ejemplificar el proceso de extracción de características de usuario. Es un hombre español de 37 años que no posee ninguna discapacidad, con un grado superior en desarrollo de videojuegos que se encuentra soltero. Actualmente trabaja en una empresa desarrolladora de videojuegos con una experiencia de 15 años. En el trabajo es una persona exigente y que siempre está buscando superarse y controlar los posibles problemas que puedan ocurrir. Posee como hobbies los deportes, la lectura, la música y aprender nuevos métodos de optimización de las aplicaciones que desarrolla. Estos datos se obtienen en la tarea 1.

En la tarea 2, el usuario ha indicado que quiere tener el tamaño predeterminado de fuente, que desea visualizar la portada de los videos, no quiere ver la descripción de los videos y no desea activar las opciones de accesibilidad. Adicionalmente, el usuario indica que quiere visualizar los videos en español de España, ya que es español y que se conecta desde su ordenador de sobremesa.

En la tarea 3, para buscar el video, el usuario ha realizado un total de 5 clics, coincidiendo exactamente con el número de clics estimados para completar esta tarea y sin visitar ninguna opción. El usuario no ha realizado ningún clic erróneo al completar la tarea. El usuario ha accedido a las opciones avanzadas para introducir el nombre del canal y el género del video que se le pedía. Por último, el tiempo total que el usuario ha necesitado para completar la tarea ha sido de 40 segundos, tiempo ligeramente superior al tiempo estimado para completar la tarea. El sistema clasifica al usuario con las siguientes métricas, la métrica *Ae* obtiene un valor de 1, la métrica *P* obtiene un valor de 1, la métrica *Com* obtiene un valor de 1, la métrica *Tt* obtiene un valor de 0.5 y la métrica *R* obtiene un valor de 1. Con estos valores de métricas, el sistema clasifica al usuario como *Experto* y estima que los objetivos del usuario son *transaccionales*.

En la tarea 4, el usuario ha accedido a todos los videos pulsando el botón de búsqueda cada vez que quería acceder a un video. Esto ha provocado que el usuario pulsase 5 veces el botón de búsqueda y que accediese a una sola opción por búsqueda. El usuario ha estado una media de 22 segundos por video y un tiempo máximo de 29 segundos en un video sin acceder de nuevo a ningún video. El usuario selecciona el video que se le requerida con una complejidad de búsqueda media. Con estos valores, el sistema el sistema ha clasificado al usuario de la siguiente manera, la métrica *Nb* ha obtenido un valor de 0.5, la métrica *Odc* ha obtenido un valor de 0.5, la métrica *Tmp* 1, la métrica *Or* ha obtenido un valor de 1, la métrica *Tmpag* ha obtenido un valor de 0.5, la métrica *Com* ha obtenido un valor de 1 y la métrica *Qc* ha obtenido un valor de

0.5. Considerando los valores de las métricas estimadas, el sistema estima que el usuario posee un objetivo navegacional.

En la tarea 5, el usuario ha accedido a la opción de “configuración de perfil de usuario” y ha procedido a validar que los valores obtenidos por los sensores que indicaban que se encontraba solo en una habitación silenciosa son correctos. El sistema aprende que el usuario está solo en el interior de una habitación.

En la tarea 6, para configurar el recordatorio, el usuario ha necesitado 13 clics, superando el número de clics estimados, que es de 10 clics. Estos clics extra se deben a que el usuario ha realizado un error pulsando iconos que no debía y ha revisitado 2 opciones. El usuario ha realizado un desplazamiento vertical de 150 píxeles en total, y ha usado una vez el botón de búsqueda. El tiempo total que el usuario ha necesitado para completar esta tarea es de 85 segundos, superando los 60 segundos estimados para completar la tarea y ha estado una media de 20 segundos por página. Esto se debe a que ha realizado 3 pausas sensibles. Con estos valores, el sistema ha clasificado al usuario de la siguiente manera, la métrica *Cu* ha obtenido un valor de 0, la métrica *Dv* ha obtenido un valor de 0.5, la métrica *Nb* ha obtenido un valor de 1, la métrica *P* ha obtenido un valor de 0.5, la métrica *Tt* ha obtenido un valor de 0.5, la métrica *Tp* ha obtenido un valor de 0.5, la métrica *Ps* ha obtenido un valor de 0.5, la métrica *Com* ha obtenido un valor de 1 y la métrica *Cq* ha obtenido un valor de 1. Considerando los valores de las métricas estimadas, el sistema estima que el usuario posee conocimientos medios sobre el sistema.

En la tarea 7, el usuario ha decidido reproducir un video de la última canción publicada de su artista preferido. El sistema ha aprendido que el usuario posee interés de escuchar música en su tiempo de ocio. Además, mediante el módulo de captura de emociones, el sistema ha determinado que su estado emocional es de relajación.

5. Experimentación

En esta investigación se busca responder la pregunta de investigación: *¿Existe una correlación entre los valores obtenidos por las métricas y las preferencias del usuario?* Considerando esta pregunta de investigación, se formula también una hipótesis nula, la cual plantea que no existe ninguna correlación entre los valores obtenidos por las métricas de usuario y sus preferencias.

5.1 Instrumentación y configuración

Este proceso de experimentación ha sido evaluado con un grupo de 60 participantes. Los participantes son estudiantes de Ingeniería del Software en el grado de Ingeniería Informática de la *Universitat de València*, por lo que poseen conocimientos

sobre el desarrollo de interfaces de usuario. Fueron contactados por correo electrónico y otorgaron su consentimiento para participar en el experimento.

Para realizar el experimento, se ha utilizado el programa QuantUX (Quantux, 2025). Este programa es una herramienta de análisis que evalúa las interacciones del usuario en distintos prototipos. Para ello, registra el tiempo requerido para completar la tarea, el número de clics y su ubicación. Además, permite analizar el contenido ingresado en los campos de texto para verificar si la tarea se ha realizado correctamente.

En este experimento, los participantes utilizaron QuantUX en sus computadoras con el objetivo de obtener los parámetros necesarios para estimar sus características. En primer lugar, completaron un formulario con información demográfica, como edad, género y nivel educativo. Posteriormente, se les pidió que interactuasen con una serie de prototipos de usuario diseñados en la plataforma, realizando tareas específicas o navegando por las interfaces propuestas. Durante esta interacción, se calcularon automáticamente métricas destinadas a medir sus características, sin que los participantes fueran conscientes de ello.

Al finalizar la interacción con los prototipos, los usuarios completaron un segundo formulario en el que indicaron sus preferencias. Esto permitió comparar estas preferencias con los valores obtenidos a través de nuestras métricas propuestas.

5.2 Factores y variables respuesta

En este experimento sigue un diseño entre-sujetos con un solo factor y nueve variables respuesta. En este experimento sólo hay un factor:

- **Procedimiento para estimar las características de usuario:** Esta variable indica el método utilizado para extraer las características del usuario. Es una variable dependiente con dos categorías: una corresponde al valor de la característica del usuario obtenido mediante las métricas propuestas en el artículo, y la otra refleja las preferencias expresadas por los propios usuarios. Gracias a esta distinción, es posible analizar la relación entre el valor calculado a partir de las métricas propuestas y el valor reportado mediante las preferencias del usuario.

Este experimento posee ocho (8) variables respuesta, una por cada característica de usuario que incluye métricas automáticas para su estimación:

- **Conocimiento:** Esta variable evalúa la capacidad del sujeto para comprender correctamente las acciones necesarias para completar la tarea.

- **Habilidades:** Esta variable mide la capacidad del sujeto para ejecutar la tarea de manera correcta.
- **Objetivos:** Esta variable identifica el propósito del sujeto al interactuar con el sistema.
- **Dispositivo:** Esta variable determina el equipo a través del cual el sujeto interactúa con el sistema.
- **Idioma:** Esta variable establece el idioma utilizado para interactuar con el sistema.
- **Nacionalidad:** Esta variable indica la ubicación del sujeto, lo que puede influir en ciertos comportamientos.
- **Contexto:** Esta variable analiza la situación en la que se encuentra el sujeto. Por ejemplo, si está solo en una habitación, se podrían activar los comandos por voz.
- **Intereses:** Esta variable identifica las preferencias y gustos del sujeto.

Las métricas automáticas para extraer el estado emocional actual del usuario y las incapacidades del usuario no han sido evaluadas como variables respuesta ya que no se disponía del software adecuado para aplicar las métricas de usuario y extraer estas características en tiempo de ejecución.

5.3 Tareas evaluadas.

El experimento se desarrolla en dos escenarios de complejidad similar, cada uno compuesto por tareas sencillas diseñadas para que la duración total no supere una hora. Cada escenario incluye varias tareas, y cada una de ellas emplea una métrica específica para evaluar determinadas características del usuario. Para garantizar una distribución equitativa, las métricas se han repartido equilibradamente entre las tareas. A continuación, se presentan las definiciones de cada escenario.

Escenario experimental 1 Sistema doméstico. Este escenario busca simular las diferentes interfaces de usuario que forman parte de un sistema doméstico. A continuación, definimos el conjunto de tareas que forman parte del escenario 1:

- Tarea 1. El sujeto debe rellenar el formulario de registro del sistema mientras que el sistema estima su idioma, su nacionalidad y su dispositivo.
- Tarea 2. El sujeto debe generar una lista de la compra con ciertos productos, mientras que el sistema procede a estimar las habilidades del usuario.
- Tarea 3. El sujeto debe configurar los errores presentes en los valores obtenidos por los sensores de la habitación del sistema doméstico, mientras que el sistema estima el contexto actual del sujeto.

- Tarea 4. El sujeto debe configurar un escenario específico para la habitación en la que se encuentra, mientras que el usuario estima los conocimientos y objetivo del usuario.
- Tarea 5. El sujeto debe reproducir el contenido multimedia que le guste más, mientras que el sistema estima los intereses del usuario.

Escenario experimental 2 Coche autónomo. Este escenario busca simular las diferentes interfaces de usuario que forman parte de un coche autónomo. A continuación, definimos el conjunto de tareas que forman parte del escenario 2:

- Tarea 1. El sujeto debe rellenar el formulario de registro del sistema mientras que el sistema estima su idioma, su nacionalidad y su dispositivo.
- Tarea 2. El sujeto debe ajustar los valores obtenidos por los sensores a su situación actual, mientras que el sistema estima su contexto.
- Tarea 3. El sujeto debe seleccionar una ruta para llegar a su casa mientras que el sistema estima sus habilidades.
- Tarea 4. El sujeto debe interactuar con la consola del sistema para cerrar las puertas del coche mientras que el sistema estima los conocimientos y objetivos del usuario.
- Tarea 5. El sujeto debe reproducir el contenido multimedia que le guste más, mientras que el sistema estima sus intereses.

La elección de estos dos escenarios se ha realizado por conveniencia estratégica. Es fundamental que la validación se base en contextos que sean funcional y contextualmente muy distintos entre sí, y en los que los participantes no tengan un nivel de experticia elevado. Hemos descartado aplicaciones relacionadas con la gestión, el comercio electrónico o los videojuegos, ya que son ampliamente utilizadas por el perfil de sujetos reclutados para el experimento. En cambio, los estudiantes suelen tener poca experiencia previa con sistemas de domótica o vehículos inteligentes, lo que convierte a ambos escenarios en opciones ideales para nuestra validación.

6. Resultados y discusión

Para evaluar si existe una correlación entre el resultado obtenido con las métricas propuestas y las preferencias de los usuarios, hemos definido la medida *porcentaje de acierto*. Este porcentaje de acierto se establece considerando como acierto aquellos casos en los que el valor de la métrica concuerda con la preferencia expresada por el usuario. De este modo, cuanto mayor sea el porcentaje de acierto, mayor será la capacidad de

la métrica para reflejar y predecir las preferencias de los sujetos del experimento.

Las métricas de usuario utilizadas para estimar La nacionalidad del usuario, el contexto, el idioma, el dispositivo, los objetivos y los intereses del usuario presentan un 100 % de precisión. Esto se debe a la alta homogeneidad de los sujetos evaluados: eran españoles, en un aula con ruido ambiental, hablaban español, tenían como objetivo realizar el experimento, se conectaron desde un ordenador, e indicaron el interés que venía especificado en la tarea. Por este motivo, no se ha llevado a cabo el análisis de los resultados obtenidos por estas métricas de usuario. Por lo que respecta a las métricas manuales, se han descartado de la validación por la misma razón. Dado que son los propios usuarios quienes les asignan valor, el resultado proporcionado por estas métricas coincidiría con las preferencias establecidas por cada usuario.

Tabla 4 Resultados obtenidos

Característica	Métrica	Precisión
Conocimiento	Cu	75 %
Conocimiento	Nb	83 %
Conocimiento	P	78 %
Conocimiento	Tt	79 %
Conocimiento	Tp	60 %
Conocimiento	Ps	89 %
Conocimiento	Com	92 %
Conocimiento	Cq	85 %
Habilidades	Co	78 %
Habilidades	Ae	89 %
Habilidades	A	75 %
Habilidades	Tt	80 %
Habilidades	R	72 %

En cambio, la mayoría de métricas automáticas encargadas de estimar los conocimientos y habilidades del usuario sí que presentan una mayor variabilidad de precisión, ya que obtienen

valores diferentes y menores al 100 % de precisión. En la Tabla 4 aparecen todas las métricas de conocimiento y habilidades con menos del 100 % de precisión.

En cuanto a la característica de conocimiento, el experimento evalúa las métricas *Cu*, *Nb*, *P*, *Tt*, *SP* y *Com*. La métrica *Dv* no se incluye, ya que el programa no permite registrar el desplazamiento vertical realizado por el usuario. Además, la métrica *Tp* no puede ser evaluada debido a que la tarea se lleva a cabo en una sola página. Por otro lado, la métrica *Cq* queda fuera del análisis, ya que el usuario no realiza ninguna búsqueda durante las tareas. En cuanto a la característica de habilidades, el experimento sí evalúa todas las métricas propuestas.

En cuanto a la característica conocimiento, este experimento ha logrado una precisión media del 80.13 % en las métricas de usuario evaluadas, aunque con un desempeño variable entre ellas. La métrica *Com* obtuvo los mejores resultados, con un 92 % de coincidencia con las preferencias del usuario. En contraste, la métrica *Tp* presentó el desempeño más bajo, alcanzando sólo un 60 % de coincidencia.

La mayoría de las métricas superaron el 75 % de precisión, lo que indica que las fórmulas utilizadas estiman correctamente las preferencias de los usuarios en comparación con sus expectativas. Estos resultados coinciden con lo previsto, ya que se esperaba un porcentaje de acierto bajo para la métrica *Tp* debido a la limitada cantidad de páginas disponibles en el experimento. Esto hace que el tiempo de permanencia en cada página sea mayor, independientemente del comportamiento del usuario. Por otro lado, los resultados de la métrica *Nb* fueron mejores de lo esperado, lo que puede explicarse por la escasez de elementos de búsqueda en las tareas. Esto llevó a que la mayoría de los usuarios asignaran una alta valoración a esta métrica.

En cuanto a las habilidades, este experimento ha logrado una precisión media del 78.80 % en las métricas de usuario evaluadas, aunque con un desempeño variable entre ellas. La métrica *Ae* obtuvo los mejores resultados, con un 89 % de coincidencia con las preferencias del usuario. Por el contrario, las métricas *R* y *A* mostraron el rendimiento más bajo, alcanzando un 75 % y un 72 %, respectivamente.

La mayoría de las métricas de las habilidades superaron el 75% de precisión, lo que indica que las fórmulas utilizadas para definir las métricas de usuario representan de manera adecuada a los usuarios en comparación con sus expectativas. Estos resultados están en línea con lo previsto, ya que se esperaba una precisión media superior al 70% en las métricas de usuario. La métrica *A* obtuvo un resultado inferior a lo esperado. Este resultado podría explicarse a través del efecto Dunning-Kruger (Gignac & Zajenkowski, 2020), el cual indica que algunos usuarios tienden a sobreestimar sus habilidades. Como

consecuencia, las métricas no coinciden con las estimaciones de los usuarios, generando una discrepancia en los valores obtenidos. Por otro lado, la métrica *Ae* superó las expectativas, ya que anticipa que los usuarios interactuaron menos con las opciones avanzadas de la tarea. Sin embargo, el mayor acceso a estas funciones incrementó la estimación de sus habilidades. Por otro lado, la métrica *R* también presentó un nivel de precisión bajo, lo cual era previsible debido a que los prototipos utilizados en las tareas ofrecían pocas opciones para que los usuarios pudieran volver a acceder a ellas. Como resultado, los usuarios tendieron a sobreestimar sus habilidades. A pesar de las observaciones señaladas en estas métricas de usuario, la característica de habilidades muestra los resultados esperados. Consideramos que el cálculo del promedio de los valores obtenidos en esta métrica ha permitido normalizar los resultados y mitigar el efecto de posibles clasificaciones erróneas en las métricas.

7. Conclusiones y trabajo futuro

Este estudio presenta un conjunto de métricas diseñadas para recopilar diversas características de los usuarios con el fin de definir su perfil y desarrollar interfaces inteligentes. Se ha incidido en identificar aquellas métricas que pueden obtenerse de manera no intrusiva mientras el usuario interactúa normalmente con el sistema (métricas automáticas). Por otro lado, las métricas que requieren información explícita del usuario se recopilan mediante formularios (métricas manuales). Ambas categorías de métricas se han extraído de la literatura existente, pero en este trabajo se especifica cómo calcularlas utilizando los parámetros propuestos. Además, se han vinculado estos dos tipos de métricas con las características que conforman el perfil dentro de un modelo de usuario.

Asimismo, se ha presentado un caso práctico que demuestra cómo el sistema recopila y utiliza la información del usuario. Finalmente, se ha llevado a cabo una fase de experimentación en la que se ha evaluado la validez de las métricas propuestas, obteniendo como resultado que las métricas relacionadas con el conocimiento y las habilidades de los usuarios presentan un alto grado de coincidencia con sus expectativas.

Como limitaciones de las métricas propuestas cabe resaltar: (1) las métricas son para un modelo de usuario específico, aunque este modelo pretende ser lo más genérico posible para dar cabida a varios perfiles de usuario para distintos contextos; (2) no se han incluido métricas para tratar aspectos éticos junto con las características de los usuarios. Puede ser que un mismo perfil de usuario requiera una u otra adaptación de la interfaz atendiendo a características éticas; (3) el grupo de usuarios evaluado es muy homogéneo, lo que podría limitar la generalización de los resultados a otros grupos de usuarios; (4) las métricas propuestas no han sido evaluadas por expertos en el campo del Diseño Centrado en el Usuario (DCU); el estudio

actual se ha centrado en usuarios finales de las aplicaciones. Este estudio se podría complementar en el futuro con expertos.

Como puntos fuertes de las métricas propuestas cabe resaltar: (1) poseen un alto grado de independencia respecto a la plataforma y lenguaje usados para su diseño; (2) poseen un alto grado de independencia de los elementos gráficos, porque la misma métrica puede ser aplicada para obtener diversas características de usuario; (3) los diseñadores no encuentran una mayor dificultad para analizar los comportamientos del usuario ya que las métricas van dentro de los elementos gráficos o dentro de los formularios del sistema.

En la discusión, se considera que las métricas más adecuadas para estimar el conocimiento y las habilidades del usuario son aquellas que evalúan si este completa correctamente una tarea. Esto se debe a que la percepción del usuario sobre dichas habilidades está influenciada por el grado de confianza que tenga en la ejecución de la tarea. Adicionalmente, se considera que la métrica encargada de determinar el género del usuario es la que menos información relevante aporta al sistema ya que existen pocos contextos en los que dicha información suponga una mejora significativa a la experiencia de usuario del sistema. Asimismo, a partir del caso explicativo, consideramos que las métricas automáticas relacionadas con el idioma y el dispositivo serán las más precisas en la recopilación de datos, mientras que la métrica de objetivos podría presentar los resultados menos favorables.

Como línea de trabajo futuro, se plantea la definición de perfiles de usuario que permitan clasificar a cada individuo según sus características. En función de esta clasificación, se asignaría a cada usuario un perfil específico, lo que facilitaría la adaptación de las interfaces a sus preferencias. También, se considera la posibilidad de seleccionar un test de usabilidad con una muestra más amplia, como el *System Usability Scale (SUS)* o el *UEQ+*, para evaluar el grado de aceptación de los usuarios respecto a las reglas establecidas para personalizar la interfaz según cada grupo de usuarios. Finalmente, se considera incluir en el futuro elementos de transparencia y ética en las métricas propuestas y realizar una fase de experimentación donde expertos DCU las evalúen también.

Agradecimientos

Este trabajo ha sido desarrollado con la ayuda de la Generalidad Valenciana con el proyecto TENTACLE (CIAICO/2023/089). También ha contado con la ayuda del ministerio español de ciencia e innovación en el proyecto SREC (PID 2021-123824OB-I00).

Referencias

- Abdelrazek, M., Purificato, E., Boratto, L., & Luca, E. W. D. (2023). FairUP: A Framework for Fairness Analysis of Graph Neural Network-Based User Profiling Models. *Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR 2023, Taipei, Taiwan, July 23-27, 2023*, 3165-3169. <https://doi.org/10.1145/3539618.3591814>
- Abri, S., Abri, R., & Çetin, S. (2020). Group-based Personalization Using Topical User Profile. *Adjunct Publication of the 28th ACM Conference on User Modeling, Adaptation and Personalization, UMAP 2020, Genoa, Italy, July 12-18, 2020*, 181-186. <https://doi.org/10.1145/3386392.3399559>
- Alhijawi, B., Fraihat, S., & Awajan, A. (2023). Adaptable inheritance-based prediction model for multi-criteria recommender system. *Multim. Tools Appl.*, 82(21), 32421-32442. <https://doi.org/10.1007/s11042-023-14728-z>
- Berkovitch, O., Caduri, S., Kahlon, N., Efros, A., Caciularu, A., & Dagan, I. (2024). Identifying User Goals from UI Trajectories. *CoRR*, abs/2406.14314. <https://doi.org/10.48550/arXiv.2406.14314>
- Chang, C.-M., Lin, C.-S., Chen, W.-C., Chen, C.-T., & Hsu, Y.-L. (2020). Development and Application of a Human-Machine Interface Using Head Control and Flexible Numeric Tables for the Severely Disabled. *Applied Sciences*, 10(19). <https://www.doi.org/10.3390/app10197005>
- Dumitrescu, A., & Santini, S. (2021). Full coverage of a reader's interests in context-based information filtering. *J. Assoc. Inf. Sci. Technol.*, 72(8), 1011-1027. <https://doi.org/10.1002/asi.24470>
- Gaspar, A., Gil, M., Panach, J. I., & Romero, V. (2024). Towards a general user model to develop intelligent user interfaces. *Multim. Tools Appl.*, 83(26), 67501-67534. <https://doi.org/10.1007/s11042-024-18240-w>
- Gignac, G. E., & Zajenkowski, M. (2020). The Dunning-Kruger effect is (mostly) a statistical artefact: Valid approaches to testing the hypothesis with individual differences data. *Intelligence*, 80, 101449. <https://doi.org/10.1016/j.intell.2020.101449>
- Gilbert, J., Hamid, S., Hashem, I. A. T., Ghani, N. B. A., & Boluwatife, F. F. (2023). The rise of user profiling in social media: Review, challenges and future direction. *Soc. Netw. Anal. Min.*, 13(1), 137. <https://doi.org/10.1007/s13278-023-01146-0>
- Gothé, S. V., Ghosh, S., Mani, S., Guggilla, B., Agarwal, A., & Sanchi, C. (2021). Language Detection Engine for Multilingual Texting on Mobile Devices. *CoRR*, abs/2101.03963. <https://doi.org/10.48550/arXiv.2101.03963>
- Hawamdeh, M., Altınay, Z., Altınay, F., Amavut, A., Ozansoy, K., & Adamu, I. (2022). Comparative analysis of students and faculty level of

- awareness and knowledge of digital citizenship practices in a distance learning environment: Case study. *Education and Information Technologies*, 27(5), 6037-6068. <https://doi.org/10.1007/s10639-021-10868-7>
- Hoi, N. T., & Que, T. D. (2024). Discovering User Interest in Social Media Based on Correlation. *Advances in Information and Communication Technology*, 403-413. https://www.doi.org/10.1007/978-3-031-50818-9_43
- Hou, W., Liu, J., & Yan, X. (2021). A Questionnaire Data Clustering Method Based on Optimized K-Modes Algorithm. *Artificial Intelligence in HCI - Second International Conference, AI-HCI 2021, Held as Part of the 23rd HCI International Conference, HCII 2021, Virtual Event, July 24-29, 2021, Proceedings*, 12797, 326-342. https://doi.org/10.1007/978-3-030-77772-2_22
- Hu, S., Kumar, A., Al-Turjman, F., Gupta, S., Seth, S., & Shubham. (2020). Reviewer Credibility and Sentiment Analysis Based User Profile Modelling for Online Product Recommendation. *IEEE Access*, 8, 26172-26189. <https://doi.org/10.1109/ACCESS.2020.2971087>
- Iqbal, M. W., Ahmad, N., Shahzad, S. K., Naqvi, M. R., Khan, B. A., & Ali, Z. (2021). User Context Ontology for Adaptive Mobile-Phone Interfaces. *IEEE Access*, 9, 96751-96762. <https://doi.org/10.1109/ACCESS.2021.3095300>
- Jarwal, M. K., Barun, A., Singh, A., & Srivastava, A. (2022). Mobile Application based Tracking using GPS and GSM. *2022 8th International Conference on Signal Processing and Communication (ICSC)*, 153-156. <https://doi.org/10.1109/ICSC56524.2022.10009250>
- Jin, Y., Tintarev, N., Htun, N. N., & Verbert, K. (2020). Effects of personal characteristics in control-oriented user interfaces for music recommender systems. *User Model. User Adapt. Interact.*, 30(2), 199-249. <https://doi.org/10.1007/s11257-019-09247-2>
- Kinjo, H., & Mbaitiga, Z. (2022). Development of flexible Text Input Device Based on Image Processing for Each Level of Disability Person. *2022 7th International Conference on Intelligent Informatics and Biomedical Science (ICIIBMS)*, 7, 378-379. <https://www.doi.org/10.1109/ICIIBMS55689.2022.9971506>
- Kubanyi, J., Hlavac, P., Simko, J., & Bielikova, M. (2018). Towards Automated Web Navigation and Search Skill Assessment: An Eye-tracking Study on the Skill Differences. *2018 13th International Workshop on Semantic and Social Media Adaptation and Personalization (SMAP)*, 49-54. <https://www.doi.org/10.1109/SMAP.2018.8501883>
- Laor, T., Mehanna, N., Durey, A., Dyadyuk, V., Laperdrix, P., Maurice, C., Oren, Y., Rouvoy, R., Rudametkin, W., & Yarom, Y. (2022). DRAWN APART: A Device Identification Technique based on Remote GPU Fingerprinting. *Proceedings 2022 Network and Distributed System Security Symposium*. <https://doi.org/10.14722/ndss.2022.24093>
- Machová, K., Szabóová, M., Paralič, J., & Mičko, J. (2023). Detection of emotion by text analysis using machine learning. *Frontiers in Psychology*, 14. <https://www.doi.org/10.3389/fpsyg.2023.1190326>
- Mangat, G., & Sharma, S. (2023). How does the use of different targeted literature review (TLR) methodologies impact the research output? *Parexel International*. <https://www.ispor.org/docs/default-source/intl2023/ispor23gsmr36poster-pdf.pdf>
- Mishra, V., Laperdrix, P., Vastel, A., Rudametkin, W., Rouvoy, R., & Lopatka, M. (2020). Don't Count Me Out: On the Relevance of IP Address in the Tracking Ecosystem. *WWW '20: The Web Conference 2020, Taipei, Taiwan, April 20-24, 2020*, 808-815. <https://doi.org/10.1145/3366423.3380161>
- Oukfif, K., Battou, F., & Bouzeffrane, S. (2020). Budget-Aware Performance Optimization of Workflows in Multiple Data Center Clouds. *Mobile, Secure, and Programmable Networking - 6th International Conference, MSPN 2020, Paris, France, October 28-29, 2020, Revised Selected Papers*, 12605, 144-160. https://doi.org/10.1007/978-3-030-67550-9_10
- Paulino, D., Ferreira, J., Netto, A., Correia, A., Ribeiro, J., Guimarães, D., Barroso, J., & Paredes, H. (2024). Probing into the Usage of Task Fingerprinting in Web Games to Enhance Cognitive Personalization: A Pilot Gamified Experience with Neurodivergent Participants. *2024 IEEE 12th International Conference on Serious Games and Applications for Health (SeGAH)*, 1-8. <https://doi.org/10.1109/SeGAH61285.2024.10639597>
- Quantux. (2025). Quant-UX. <https://app.quant-ux.com>
- Rao, N., Bansal, C., Mukherjee, S., & Maddila, C. (2020). Product Insights: Analyzing Product Intents in Web Search. *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*, 2189-2192. <https://doi.org/10.1145/3340531.3412090>
- Rybczewska, M., & Sparks, L. (2022). Ageing consumers and e-commerce activities. *Ageing and Society*, 42(8), 1879-1898. <https://www.doi.org/10.1017/S0144686X20001932>
- Sajana, S. T., Jacob, S., P. V., Menon, V. G., & C. S. P. (2022). Context-aware gender and age recognition from smartphone sensors. *2022 International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS)*, 1-6. <https://www.doi.org/10.1109/IC3SIS54991.2022.9885610>
- Salem, I. E., & Al-Saedi, K. H. (2023). Intensive Malware Detection Approach based on Data Mining. *Journal of Applied Engineering and Technological Science (JAETS)*, 5(1), 414-424. <https://www.doi.org/10.37385/jaets.v5i1.2865>
- Sandoval-Gaytan, B. D., Camacho, L.-M., & Vazquez-Hurtado, C. (2023). Point Cloud Generation of Transparent Objects: A Comparison between Technologies. *2023 IEEE Global Engineering Education Conference (EDUCON)*, 1-3. <https://doi.org/10.1109/EDUCON54358.2023.10125143>
- Schmidt, A., Mayer, S., & Buschek, D. (2021). Introduction to Intelligent User Interfaces. *Extended Abstracts of the 2021 CHI Conference on Human Factors in Computing Systems*. <https://doi.org/10.1145/3411763.3445021>
- Sepulveda, G. K., Besoain, F., & Barriga, N. A. (2020). Exploring Dynamic Difficulty Adjustment in Videogames. *CoRR*, abs/2007.07220. <https://www.doi.org/10.1109/CHILECON47746.2019.8988068>
- Shi, S. W., & Trusov, M. (2021). The Path to Click: Are You on It? *Mark. Sci.*, 40(2), 344-365. <https://doi.org/10.1287/mksc.2020.1253>
- Sikder, A. K., Aksu, H., & Uluagac, A. S. (2020). A Context-Aware Framework for Detecting Sensor-Based Threats on Smart Devices. *IEEE Trans. Mob. Comput.*, 19(2), 245-261. <https://doi.org/10.1109/TMC.2019.2893253>

- Singh, S. (2022). Emphasis on the Minimization of False Negatives or False Positives in Binary Classification. CoRR, abs/2204.02526. <https://doi.org/10.48550/arXiv.2204.02526>
- Šumak, B., Kous, K., Martínez-Normand, L., Pekša, J., & Pušnik, M. (2023). Identification of Challenges and Best Practices for Including Users with Disabilities in User-Based Testing. *Applied Sciences*, 13(9). <https://www.doi.org/10.3390/app13095498>
- Sun, B., Mao, H., & Yin, C. (2020). Male and Female Users' Differences in Online Technology Community Based on Text Mining. *Frontiers in Psychology*, 11. <https://www.doi.org/10.3389/fpsyg.2020.00806>
- Tufail, S., Riggs, H., Tariq, M., & Sarwat, A. I. (2023). Advancements and Challenges in Machine Learning: A Comprehensive Review of Models, Libraries, Applications, and Algorithms. *Electronics*, 12(8). <https://www.doi.org/10.3390/electronics12081789>
- Vandic, D., Nederstigt, L. J., Frasincar, F., Kaymak, U., & Ido, E. (2024). A framework for approximate product search using faceted navigation and user preference ranking. *Data Knowl. Eng.*, 149, 102241. <https://doi.org/10.1016/j.datak.2023.102241>
- Wang, B., & Liu, J. (2023). Characterizing and Early Predicting User Performance for Adaptive Search Path Recommendation. *Proceedings of the Association for Information Science and Technology*, 60(1), 408-420. <https://doi.org/10.1002/pra2.799>
- Wu, D., Du, X., & Peng, F. (2024). Multi-layer and multi-source features stacking ensemble learning for user profile. *Electric Power Systems Research*, 229, 110128. <https://doi.org/10.1016/j.epsr.2024.110128>
- Yu, R., Gadiraju, U., Holtz, P., Rokicki, M., Kemkes, P., & Dietze, S. (2018). Predicting User Knowledge Gain in Informational Search Sessions. *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval, SIGIR 2018, Ann Arbor, MI, USA, July 08-12, 2018*, 75-84. <https://doi.org/10.1145/3209978.3210064>
- Yu, R., Tang, R., Rokicki, M., Gadiraju, U., & Dietze, S. (2021). Topic-independent modeling of user knowledge in informational search sessions. *Inf. Retr. J.*, 24(3), 240-268. <https://doi.org/10.1007/s10791-021-09391-7>
- Zhou, J., Zahiri, S. M., Hughes, S., Jadda, K. A., Kallumadi, S., & Agichtein, E. (2021). De-Biased Modeling of Search Click Behavior with Reinforcement Learning. *SIGIR '21: The 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, Virtual Event, Canada, July 11-15, 2021*, 1637-1641. <https://doi.org/10.1145/3404835.3463228>
- Ziosi, M., Hewitt, B., Juneja, P., Taddeo, M., & Floridi, L. (2024). Smart cities: Reviewing the debate about their ethical implications. *AI Soc.*, 39(3), 1185-1200. <https://doi.org/10.1007/s00146-022-01558-0>