

Definición de métricas para extraer un perfil de usuario

Alberto Gaspar

Escola Tècnica Superior d'Enginyeria. Departament d'informàtica.

Universitat de València. Valencia, Avenida de la Universidad s/n, 46100 Burjassot

alberto.gaspar@uv.es

Miriam Gil

Escola Tècnica Superior d'Enginyeria. Departament d'informàtica.

Universitat de València. Valencia, Avenida de la Universidad s/n, 46100 Burjassot

miriam.gil@uv.es

José Ignacio Panach

Escola Tècnica Superior d'Enginyeria. Departament d'informàtica.

Universitat de València. Valencia, Avenida de la Universidad s/n, 46100 Burjassot

joigpana@uv.es

Verónica Romero

Escola Tècnica Superior d'Enginyeria. Departament d'informàtica.

Universitat de València. Valencia, Avenida de la Universidad s/n, 46100 Burjassot

veronica.romero@uv.es

ABSTRACT

Las interfaces inteligentes tienen como objetivo adaptar los elementos gráficos en tiempo de ejecución en base al perfil del usuario que está interactuando con el sistema. Para llevar a cabo esta adaptación, el sistema debe extraer el perfil del usuario de la forma menos intrusiva posible. Para automatizar este proceso, se deben definir mecanismos de extracción de las características del usuario mientras interactúa con el sistema en sus acciones habituales. La contribución de este trabajo es la propuesta de unas métricas encargadas de recopilar las características de usuario necesarias para definir el perfil de usuario. Las características se almacenarán en un modelo de usuario previamente definido. Estas métricas se han definido a partir de trabajos previos, donde como contribución de este artículo hemos definido los parámetros para calcularlas. Además, hemos diferenciado las métricas que se pueden calcular de forma automática, de las que deben calcularse manualmente. Este trabajo es un paso más para definir una metodología que permita diseñar interfaces de usuario inteligentes capaces de adaptarse en tiempo de ejecución a las características del usuario en función de cómo lo hicieron usuarios con similares características. A modo de ejemplo ilustrativo se muestra un caso práctico donde se ve cómo extraer las métricas propuestas.

CCS CONCEPTS

• Information systems • Human-centered computing Human computer interaction (HCI) • Computing methodologies~ Artificial intelligence • Computers and society

KEYWORDS

Perfil de usuario, métricas de usuario, Características de usuario, Adaptación.

ACM Reference format:

Alberto Gaspar, Miriam Gil, José Ignacio Panach and Verónica Romero. 2024. Definición de métricas para extraer un perfil de usuario. In *Proceedings of INTERACCIÓN 2024*.

Las interfaces de usuario inteligentes (IUI) son un subcampo parte de la interacción persona-ordenador (IPO) centrado en mejorar la experiencia de usuario, la usabilidad y el compromiso de los usuarios que interactúan con el sistema. Para ello, estas interfaces 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 [1]. 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. Hou et al. [2], definen una métrica de usuario como una medida que tiene como objetivo extraer las características del usuario mientras éste interactúa con el sistema para capturar las características de los usuarios y las configuraciones que el usuario espera del sistema. 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 [3].

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 [4]. 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. Otro ejemplo podría ser en una tienda de videojuegos, donde el sistema puede establecer diferentes grupos de perfiles de usuario en función de la edad del usuario y ajustar los videojuegos mostrados a la edad del usuario y a la edad PEGI (pan european game information) de dicho videojuego.

1 Introducción

Automatizar el proceso de extracción de características de usuario es un proceso complejo de implementar, pero aporta una serie de beneficios. La automatización de este proceso ayuda a aumentar la eficiencia de dicho proceso porque ayuda a reducir el tiempo necesario para procesar la información. También permite reducir el coste y el tiempo necesario para recogerlas porque se procesan mientras el usuario interactúa con el sistema. 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. [5, 6].

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 [7].

La principal contribución de este artículo es la propuesta de un conjunto de métricas de usuario para extraer las características de los usuarios necesarias para implementar correctamente el perfil de usuario (almacenado en el modelo de usuario). Estas métricas propuestas se han extraído de trabajos previos. El principal problema es que estos trabajos previos no especifican los parámetros concretos para calcular el valor de las métricas. Nuestra contribución, además de la identificación de las métricas en la literatura existente, consiste en la definición de estos parámetros. Las métricas identificadas se han clasificado en métricas automáticas (el sistema puede recogerlas automáticamente) o métricas manuales (el usuario necesita introducir el valor de estas métricas). Se pretende que el número de métricas automáticas sea el mayor posible.

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 trabajo 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. Finalmente, la sección 5 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 [8]. 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 [9]. La privacidad de los datos de los usuarios se trata de un reto de definición de métrica 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 [10].

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. En [11], por ejemplo, se presenta FairUp, 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 este. En [12], se investiga Dynamic Difficult Adjustment (DDA). Esta metodología almacena de forma dinámica las habilidades y conocimientos de los usuarios a partir del número de vidas perdidas o el 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. En [13], por ejemplo, se presenta un método de definición de perfil de usuario llamado Dynamic User Interest Print (D-UIP), que almacena de forma dinámica las preferencias de los usuarios.

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

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. Se pretende que estas métricas sean lo más automáticas posibles para no ser intrusivas. 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) [14], 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 sus parámetros.

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 [7] 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 tabla 1 muestra las diferentes características de usuario que se obtienen automáticamente, las métricas que definen el valor de la característica y los posibles rangos de valores que se pueden obtener para cada métrica. 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 Mc vale 1, el peso es 1. Las métricas que aparecen sin rango se debe a que son cálculos auxiliares de otras métricas.

Característica	Métrica	Rango
Conocimiento	$Cu = \text{Sum}(\text{clics usuario})$ [15]	
	$Cud = \text{Sum}(\text{diferentes opciones})$ [15]	
	$Cuo = \text{SUM}(\text{clic usuario en opciones})$ [15]	
	$Mc = Cu - clics_estimados $	$Mc = 1; 1$ $Mc \leq 2; 0.5$ $Mc > 2; 0$
	$Msd = Des_{usuario} - Des_{estimado} $ [15]	$Msd = 0; 1$ $Msd \leq 200; 0.5$ $Msd > 200; 0$
	$NB = \text{SUM}(\text{clics en search})$	$Nb = 0; 1$ $Nb \leq 3; 0.5$ $Nb > 3; 0$
	$P = Cu - Cuo $ [16]	$P = 0; 1$ $P \leq 2; 0.5$ $P > 2; 0$
	$Tt = \text{tiempo}U - estimado $ [16]	$Tt = 0; 1$ $Tt \leq 15; 0.5$ $Tt > 15; 0$
	$Tp = \frac{\text{Tiempo_total}}{\text{Páginas}}$ [17]	$Tp \geq 10; 1$ $Tp \leq 20; 0.5$ $Tp > 20; 0$
	$Sp = \text{SUM}(\text{inactividad} > 5 \text{ segs})$ [16]	$SP = 0; 1$ $SP \leq 3; 0.5$ $SP > 3; 0$
	$Com = \text{¿Usuario completa la acción?}$	$Com = Si; 1$ $Com = No; 0$
$Cq = \text{complejidad de la query}$ [15]	$Cq = Alta; 1$ $Cq = Media; 0.5$ $Cq = Baja; 0$	
Habilidades	$Cu = \text{Sum}(\text{clics usuario})$ [15]	
	$Cuo = \text{SUM}(\text{clic usuario en opciones})$ [15]	
	$Co = Cuo - opciones_formulario $	$Co = 0; 1$ $Co \leq 2; 0.5$ $Co < 2; 0$
	$Ae = \text{Promedio}(\text{acciones especiales})$	$Ae = 1; 1$ $Ae \leq 0.7; 0.5$ $Ae < 0.7; 0$
	$P = Cu - Cuo $ [16]	$P = 0; 1$ $P \leq 2; 0.5$ $P > 2; 0$
	$Com = \text{¿Usuario completa la acción?}$	$Com = Si; 1$ $Com = No; 0$
	$Tt = \text{tiempo}U - estimado $ [16]	$Tt = 0; 1$ $Tt \leq 15; 0.5$ $Tt > 15; 0$
	$R = Cu - opciones_sistema $ [17]	$R = 0; 1$ $R \leq 3; 0.5$ $R > 3; 0$
Objetivos	$Ov = \text{Sum}(\text{opciones accedidas})$ [15]	
	$Od = \text{Sum}(\text{distintas opciones accedidas})$ [15]	
	$NB = \text{SUM}(\text{clics en search})$	$Nb = 1; 1$ $Nb \leq 5; 0.5$

	$Nb > 5; 0$	
	$Odc = \frac{Od}{consultas}$	$Odc < 1; 1$ $Odc \leq 3; 0.5$ $Odc > 3; 0$
	$T_{mp} = \frac{Tiempo\ total}{Número\ páginas\ visitadas}$ [17]	$T_{mp} = 20; 1$ $T_{mp} \leq 5; 0.5$ $T_{mp} > 5; 0$
	$Or = Ov - Od $ [17]	$Or = 0; 1$ $Or \leq 3; 0.5$ $Or > 3; 0$
	$T_{Mpag} = MAX(tiempo_paginas)$ [17]	$T_{Mpag} < 10; 1$ $T_{Mpag} \leq 5; 0.5$ $T_{Mpag} > 5; 0$
	Com = comprobar si usuario realiza todos los pasos para completa una acción	$Com = Si; 1$ $Com = No; 0$
	$Cq = complejidad\ de\ la\ query$ [15]	$Cq = Alta; 1$ $Cq = Media; 0.5$ $Cq = Baja; 0$
Dispositivo	Identificar mediante sistema operativo.	Tipo dispositivo
Idioma	Identificar idioma del sistema operativo	Cualquier idioma existente
	Identificar idioma del teclado	
Nacionalidad	Identificar ubicación sensor GPS	Cualquier nacionalidad
	Obtener a partir de IP [18]	
Discapacidades	Identificar periféricos. [19]	Movilidad Visual Cognitiva Otra
	Identificar si activa diferentes opciones de accesibilidad	
Contexto	Sensor de Movimiento	Solo Acompañado En movimiento Parado Disponible para hablar Solo interactúa táctilmente Ocupado Disponible Al aire libre
	Obtener información sensores movimiento, calor, proximidad, acústico, micrófono, osciloscopio, velocímetro, tensiómetro, luz ambiental. [20, 21]	
Intereses	Obtener el tipo de opción o página a la que accede el usuario. [22]	Interesado No Interesado
	Comprobar si el usuario accede a las recomendaciones del sistema.	
Emociones	Máchova et al. [23]	Tristeza Alegria Miedo Sorpresa Ira Miedo

Tabla 1. Resumen de las métricas automáticas y sus valores.

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 [24]. Esta característica depende del promedio de varias métricas. La métrica *Cu* consiste en contar todos clics del usuario. La métrica *Cud* se basa en contar las diferentes opciones que ha clicado el usuario. La métrica *Cuo* consiste en obtener el número de opciones a las que accede el usuario. La métrica *Mc* realiza la resta absoluta entre el valor de *Cu* y los clics estimados para completar la tarea. La métrica *Msd* realiza la resta absoluta entre el desplazamiento vertical (scroll) realizado por el usuario y el estimado. La métrica *NB* obtiene el número de búsquedas que ha realizado el usuario. La métrica *P* consiste en realizar la resta absoluta entre los *Cu* y los *Cuo* de forma que así se obtienen los clics en los que el usuario no ha seleccionado ninguna opción. La métrica *Tt* se basa en realizar

la resta absoluta entre el tiempo que ha necesitado el usuario para completar la tarea y el estimado. La métrica *Tp* consiste en obtener un valor medio de tiempo que el usuario interactúa con cada página. La métrica *Sp* se basa en contar los periodos de inactividad del usuario que son superiores a 5 segundos. La métrica *Com* comprueba si el usuario ha realizado correctamente la tarea y *Cq* 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).

La característica **habilidades** trata de definir la capacidad del usuario para interactuar correctamente con el sistema, es decir, analiza las diferentes acciones del usuario para determinar cuándo se equivoca el usuario al realizar una acción en el sistema [25]. Esta característica depende del promedio de varias métricas. La métrica *Cu* consiste en contar todos clics del usuario. La métrica *Cuo* se basa en obtener el número de opciones a las que accede el usuario. La métrica *Co* realiza la resta absoluta de *Cu* del usuario 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* 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* se basa en realizar la resta absoluta entre los *Cu* y los *Cuo* de forma que así se obtienen los clics en los que el usuario no ha seleccionado ninguna opción. La métrica *Com* comprueba si el usuario ha podido completar correctamente la tarea. La métrica *Tt* realiza la resta absoluta entre el tiempo que ha necesitado el usuario para completar la tarea y el estimado. La métrica *R* 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 métrica *Ov* consiste en obtener el número de opciones que el usuario ha visitado. La métrica *Od* se basa en obtener el número de opciones distintas en las que el usuario ha accedido. La métrica *NB* obtiene el número de búsquedas realizadas por el usuario. La métrica *Odc* consiste en comprobar el número de opciones distintas a las que el usuario accede por cada consulta. La métrica *Tmp* obtiene el tiempo medio que el usuario está interactuando con cada opción. La métrica *Or* se basa en realizar la resta absoluta entre la métrica *Ov* y *Od* para obtener el número de opciones diferentes a las que accede el usuario. La métrica *T_Mpag* calcula el tiempo máximo que el usuario ha interactuado con una opción específica. La métrica *Com* comprueba si el usuario ha realizado todos los pasos necesarios para completar una acción específica del usuario y *Cq* calcula la complejidad de las diferentes consultas de texto realizadas. El valor final de esta característica se calcula con el promedio entre todas las métricas. Según la literatura

[26], 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. Estos tres tipos de objetivos se definieron inicialmente para sistemas web, pero nosotros consideramos que dichos objetivos también se pueden extrapolar a otros sistemas, como puede ser un sistema domótico o un vehículo inteligente.

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. 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. 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. En el caso de no coincidir, el sistema preguntará al usuario cuál de los idiomas detectados prefiere.

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. La segunda de estas métricas consiste en obtener la nacionalidad mediante la IP con la que se conecta al servidor [18]. 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 [27]. Esta característica se compone de dos métricas. La primera consiste en analizar los diferentes periféricos para verificar si algunos de estos periféricos están destinados a personas con discapacidades [19]. 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. La combinación de ambas métricas permite identificar 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 para poder ofrecer el modo de interacción más acorde al contexto del usuario [28]. 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 [20, 21].

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 [29]. 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 [22]. 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.

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. [23], 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. [30] 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 [31].

Las características **trabajo, perfil y experiencia laborales** son también relevantes según los trabajos de Jin et al. [32]. 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.

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 [33].

La característica **salario** está relacionada con el posible presupuesto que puede tener el usuario para realizar compras o suscripciones en el sistema [34]. 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. Cada búsqueda debe poseer su propio presupuesto, ya que hay muchos valores que determinan precios muy diferentes para el mismo producto, como la marca del producto, su ubicación y el envío [34]. 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 [35].

4 Ejemplo Ilustrativo

En esta sección se va a mostrar un ejemplo de uso de estas métricas de usuario. Para ello, se va a definir un sistema domótico que ilustra cómo se recopilan las características del usuario a través de las métricas. Para este escenario, el usuario debe realizar 6 tareas, las dos primeras son para establecer las métricas manuales y las 4 últimas para establecer 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, dispositivo, discapacidades, aficiones, nivel de estudios.
- **Tarea 2:** El usuario establece sus preferencias. La característica que se define es preferencias.
- **Tarea 3:** El usuario debe generar la lista de la compra de unos productos específicos, mientras que el sistema automáticamente se encarga de recopilar las habilidades y objetivos del usuario.
- **Tarea 4:** El usuario debe configurar los valores obtenidos por los sensores de proximidad, de movimiento, micrófono y webcam mientras el sistema detecta automáticamente el contexto del usuario.
- **Tarea 5:** El usuario debe configurar un escenario que controle la iluminación de una habitación mientras el sistema se encarga automáticamente de evaluar los conocimientos del usuario.

- **Tarea 6:** El usuario debe elegir el contenido multimedia que prefiera mientras el sistema automáticamente registra los posibles intereses del usuario.

A continuación, vamos a representar a dos usuarios como protopersonas que harán estas tareas para ejemplificar cómo funcionan las métricas. El **usuario 1** es un hombre español de 37 años que no posee ninguna discapacidad, con un nivel de estudios de grado superior, que trabaja en una consultora de informática, con una experiencia de 15 años, un salario entre 1000€ y 1500€ mensuales y posee como aficiones los deportes, en especial el fútbol. Toda esta información, ha sido obtenida de forma por el sistema en la tarea 1.

En la tarea 2, el usuario ha seleccionado como predeterminado el tamaño normal de fuente y el tema claro. El usuario no ha activado ninguna configuración de accesibilidad ni los comandos por voz. Por último, el usuario ha indicado que únicamente quiere recibir las notificaciones del sistema en la consola central.

En la tarea 3, para generar la lista de compra, el usuario ha realizado un total de 15 clics, superando el número de clics estimados para esta tarea que es de 10 clics. De los 5 clics extras del usuario, 3 de ellos son causados por errores del usuario, como por ejemplo pulsar fuera del icono para seleccionar el producto. Los otros 2 fueron causados por visitar el catálogo de productos. El usuario no ha realizado ninguna acción especial para seleccionar los productos. Por último, el tiempo total del usuario ha sido de 45 segundos, superando los 40 segundos estimados para completar la tarea. Teniendo en cuenta esto, el sistema estima que el usuario tenía un nivel de habilidades *novato* en el uso de estos sistemas. Además, el sistema ha detectado que el usuario ha realizado tareas que tienen como objetivo seguir una serie de pasos, de forma que, si uno de los pasos no se realiza correctamente, no se realiza la acción ya que si no sigues todos los pasos no generas la lista de la compra correctamente. Teniendo en cuenta esto, el sistema registra que las tareas realizadas por el usuario poseen un objetivo *transaccional*.

En la tarea 4, el usuario ha accedido a la opción de “configuración de sensores” y ha procedido a modificar los valores obtenidos por los sensores, ya que los sensores detectaban a dos usuarios, aunque solo hay uno en la habitación. El sistema aprende que el usuario está solo en el interior de una habitación.

En la tarea 5, para configurar el escenario, el usuario ha necesitado 30 clics, superando el número de clics estimados, que es de 23 clics. El usuario no seleccionó la opción correcta ya que seleccionó la opción de “modificar escenario” en vez de “crear escenario” bajando notablemente su precisión y provocando que el usuario revisitase la opción principal. El usuario ha indicado que desea poner “escenario 1” al escenario creado por lo que el sistema identifica que ese usuario tiene conocimientos bajos porque utiliza un término muy simple que no ayuda a identificar correctamente el escenario. Por último, el usuario ha necesitado 100 segundos para completar la tarea realizando tres pausas sensibles. Todas estas métricas indican que el usuario posee conocimientos *bajos* de este sistema.

En la tarea 6, el usuario ha decidido reproducir su lista de música preferida por los altavoces de la habitación en la que se encontraba actualmente. El sistema ha aprendido que el usuario posee interés en reproducir música en sus momentos de ocio. Además, mediante el sistema de reconocimiento de emociones, el sistema ha detectado que el usuario ha realizado estas tareas en un estado emocional nervioso.

El **usuario 2**, es una mujer de 40 años, escocesa, que tiene configurado el sistema en inglés y que tiene un nivel de estudios de máster universitario en administración de empresas, que trabaja como gerente en una empresa de economía, con una experiencia de 10 años, un salario entre 4000€ y 4500€ y que posee como aficiones la lectura de foros de economía. Además, el sistema ha detectado que este usuario posee activas las opciones de accesibilidad de su sistema que hace el tamaño de la fuente más grande de lo normal, y posee un dispositivo especial para usuarios con movilidad reducida en las manos. Toda esta información, ha sido obtenida de forma por el sistema en la tarea 1.

En la tarea 2, el usuario ha seleccionado como predeterminado el tamaño grande de fuente y el tema oscuro. El usuario ha activado la opción de alto contraste, ha modificado la presión necesaria para detectar una pulsación, y ha activado los comandos por voz y la ayuda de asistencia. Por último, el usuario ha indicado que desea recibir todas las notificaciones tanto en la consola central del sistema como en su dispositivo inteligente.

En la tarea 3, para generar la lista de la compra, realizado el número estimado de clics (10 clics). El usuario ha usado el zoom para aumentar la fuente de los productos, ha realizado la búsqueda avanzada para filtrar los productos y ha indicado que solo se muestren los productos con baja cantidad en el almacén. Por último, el tiempo total del usuario ha sido de 38 segundos, que es inferior a los 40 segundos estimados. Teniendo en cuenta esto, el sistema estima que el usuario tenía un nivel de habilidades *experto* en el uso de estos sistemas. Además, el sistema ha detectado que el usuario ha realizado tareas que tienen como objetivo seguir una serie de pasos, de forma que, si uno de los pasos no se realiza correctamente, no se realiza la acción ya que si no sigues todos los pasos no generas la lista de la compra correctamente. Teniendo en cuenta esto, el sistema registra que las tareas realizadas por el usuario poseen un objetivo *transaccional*.

En la tarea 4, el usuario ha accedido a la opción de “configuración de sensores” y ha procedido a modificar los valores obtenidos por los sensores. Dichos sensores detectaron un solo usuario en la habitación y el usuario no ha realizado ninguna modificación. En este caso, el sistema ha detectado que el usuario se encontraba solo en el interior de la habitación.

En la tarea 5, para configurar el escenario, ha empleado el número estimado de clics para completar la tarea (23 clics). El usuario no produjo ningún error cuando realizó esta tarea, por lo que mantuvo una precisión alta. El usuario ha seleccionado el nombre “escenario para cuando no haya nadie en la habitación”. Este nombre de escenario es claro y conciso, además de poseer 9 términos únicos que ayudan a identificar correctamente al escenario. Por último, el

usuario ha necesitado 80 segundos sin realizar ninguna pausa excesiva, cuando el tiempo óptimo era de 82 segundos. Todas estas métricas indican que el usuario posee unos conocimientos *altos* sobre este sistema.

En la tarea 6, el usuario ha decidido reproducir un podcast específico que estaba disponible en la aplicación *YouTube*. El sistema ha aprendido que el usuario posee interés en escuchar podcasts en su tiempo de ocio. Además, mediante el sistema de reconocimiento de emociones, el sistema ha detectado que el usuario ha realizado las tareas en un estado emocional tranquilo.

5 Conclusiones

Este trabajo propone unas métricas de usuario que permiten recopilar las diferentes características de usuario necesarias para definir el perfil de usuario y diseñar interfaces inteligentes. Se ha puesto especial énfasis en identificar las métricas que se pueden definir de forma no intrusiva mientras el usuario realiza sus actividades habituales con el sistema (métricas automáticas). Las métricas que dependen de datos proporcionados explícitamente por el usuario se obtienen mediante formularios (métricas manuales). Los dos tipos de métricas se han obtenido a partir de la literatura, pero este trabajo define cómo calcularlas con los parámetros propuestos. Los dos tipos de métricas se han relacionado con las características que registran el perfil en un modelo de usuario. Por último, se ha mostrado un caso práctico donde se ilustra cómo el sistema recopila las características del usuario.

Este proceso de extracción de características es un paso previo al diseño de interfaces inteligentes que se adapten en tiempo de ejecución al valor de estas métricas. Como puntos fuertes de las métricas propuestas cabe resaltar: (1) son independientes de plataforma y lenguaje; (2) son independientes de elementos gráficos, la misma métrica puede ser útil para diversos elementos; (3) no conlleva una dificultad añadida para los diseñadores gráficos porque van dentro de las acciones habituales a desarrollar o dentro de formularios específicos.

Como discusión, se considera que las métricas de género y salario del usuario son las que menos información relevante aportan al perfil del usuario mientras que las métricas de usuario de habilidades, conocimiento y objetivos del usuario son las que más información relevante aportan. Además, basándonos en el caso explicativo, nosotros consideramos que las métricas automáticas de idioma y dispositivo van a obtener los mejores resultados mientras que la métrica objetivos es la que peor resultado puede obtener.

Como trabajo futuro planeamos definir perfiles de usuario donde clasificar cada uno de los usuarios. En base a las características de cada usuario, se le clasificaría en un perfil. Las interfaces se adaptarían en base a las preferencias de ese perfil. Otro trabajo futuro consiste en elegir una escala de usabilidad como puede ser System usability Scale (SUS) o UEQ+ que determine la aceptación del usuario de las diferentes reglas definidas para adaptar la interfaz de usuario a cada grupo de usuarios.

ACKNOWLEDGMENTS

Este trabajo ha sido desarrollado con la ayuda de la Generalidad Valenciana con TENTACLE (GVRTE/2023/4592166). También ha contado con la ayuda del ministerio español de ciencia e innovación cofinanciado con FEDER en el proyecto SREC (PID2021-123824OB-I00).

REFERENCES

- Schmidt, A., Mayer, S., Buschek, D.: Introduction to Intelligent User Interfaces. 2021. In: Extended Abstracts of the 2021 CHI Conference on Human Factors in Computing Systems, pp. Article 129. Association for Computing Machinery, <https://www.doi.org/10.1145/3411763.3445021>
- Hou, W.J., Liu, J.X., Yan, X.Y.: A Questionnaire Data Clustering Method Based on Optimized K-Modes Algorithm. 2021. In: Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), pp. 326-342. https://www.doi.org/10.1007/978-3-030-77772-2_22
- Wu, D., Du, X., Peng, F.: Multi-layer and multi-source features stacking ensemble learning for user profile. 2024. *Electric Power Systems Research*, 229, 110128. <https://doi.org/10.1016/j.epsr.2024.110128>
- Abri, S., Abri, R., Çetin, S.: Group-based Personalization Using Topical User Profile. 2020. pp. 181-186. <https://www.doi.org/10.1145/3386392.3399559>
- Ziosi, M., Hewitt, B., Juneja, P., Taddeo, M., Floridi, L.: Smart cities: reviewing the debate about their ethical implications. 2022. *AI & SOCIETY*, <https://www.doi.org/10.1007/s00146-022-01558-0>
- Hu, S., Kumar, A., Al-Turjman, F., Gupta, S., Seth, S., Shubham: Reviewer Credibility and Sentiment Analysis Based User Profile Modelling for Online Product Recommendation. 2020. *IEEE Access*, 8, 26172-26189. <https://www.doi.org/10.1109/ACCESS.2020.2971087>
- Gaspar, A., Gil, M., Panach, J.I., Romero, V.: Towards a general user model to develop intelligent user interfaces. 2024. *Multimedia Tools and Applications*, <https://www.doi.org/10.1007/s11042-024-18240-w>
- Tufail, S., Riggs, H., Tariq, M., Sarwat, A.I.: Advancements and Challenges in Machine Learning: A Comprehensive Review of Models, Libraries, Applications, and Algorithms. *Electronics*. 2023, vol. 12, <https://www.doi.org/10.3390/electronics12081789>
- Singh, S.: Emphasis on the Minimization of False Negatives or False Positives in Binary Classification. 2022. *CoRR*, <https://www.doi.org/10.48550/ARXIV.2204.02526>
- Gilbert, J., Hamid, S., Hashem, I.A.T., Ghani, N.A., Boluwatife, F.F.: The rise of user profiling in social media: review, challenges and future direction. 2023. *Social Network Analysis and Mining*, 13, 137. <https://www.doi.org/10.1007/s13278-023-01146-0>
- Abdelrazek, M., Purificato, E., Boratto, L., De Luca, E.W.: FairUP: A Framework for Fairness Analysis of Graph Neural Network-Based User Profiling Models. 2023. In: SIGIR 2023 - Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 3165-3169. <https://www.doi.org/10.1145/3539618.3591814>
- Sepulveda, G., Besoain, F., Barriga, N.A.: Exploring Dynamic Difficulty Adjustment in Videogames. 2019. In: IEEE CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), pp. 1-6. IEEE, <https://www.doi.org/10.1109/CHILECON47746.2019.8988068>
- Alhijawi, B., Fraihat, S., Awajan, A.: Adaptable inheritance-based prediction model for multi-criteria recommender system. 2023. *Multimedia Tools and Applications*, 82, 32421-32442. <https://www.doi.org/10.1007/s11042-023-14728-z>
- Mangat, G., Sharma, S.: (2023) How does the use of different targeted literature review (TLR) methodologies impact the research output? En el *Parexel International*, <https://www.ispor.org/docs/default-source/intl2023/ispor23gsinghmsr36poster-pdf.pdf>
- Wang, B., Liu, J.: Characterizing and Early Predicting User Performance for Adaptive Search Path Recommendation. 2023. *Proceedings of the Association for Information Science and Technology*, 60, 408-420. <https://doi.org/10.1002/pra2.799>
- Yu, R., Gadiraju, U., Holtz, P., Rokicki, M., Kemkes, P., Dietze, S.: Predicting User Knowledge Gain in Informational Search Sessions. 2018. pp. 75-84. <https://www.doi.org/10.1145/3209978.3210064>
- Yu, R., Tang, R., Rokicki, M., Gadiraju, U., Dietze, S.: Topic-independent modeling of user knowledge in informational search sessions. 2021. *Inf. Retr. J.*, 24, 240-268. <https://www.doi.org/10.1007/S100791-021-09391-7>
- Mishra, V., Laperdrix, P., Vastel, A., Rudametkin, W., Rouvay, R., Lopatka, M.: Don't Count Me Out: On the Relevance of IP Address in the Tracking Ecosystem. 2020. In: *Proceedings of The Web Conference 2020*, pp. 808-815. Association for Computing Machinery, <https://www.doi.org/10.1145/3366423.3380161>
- Chang, C.-M., Lin, C.-S., Chen, W.-C., Chen, C.-T., Hsu, Y.-L.: Development and Application of a Human-Machine Interface Using Head Control and Flexible Numeric Tables for the Severely Disabled. *Applied Sciences*. 2020, vol. 10, <https://www.doi.org/10.3390/app10197005>
- Sikder, A.K., Aksu, H., Uluagac, A.S.: A Context-Aware Framework for Detecting Sensor-Based Threats on Smart Devices. 2020. *IEEE Trans. Mob. Comput.*, 19, 245-261. <https://www.doi.org/10.1109/TMC.2019.2893253>
- Sajana T. S., Susmi, J., Vinod, P., Varun, G.M., Shilpa P. C.: Context-aware gender and age recognition from smartphone sensors. 2022. In: *International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS)*, pp. 1-6. <https://www.doi.org/10.1109/IC3SIS54991.2022.9885610>
- Hoi, N.T., Que, T.D.: Discovering User Interest in Social Media Based on Correlation. 2024. In: *Lecture Notes in Networks and Systems*, pp. 403-413. https://www.doi.org/10.1007/978-3-031-50818-9_43
- Machová, K., Szabóová, M., Paralič, J., Mičko, J.: Detection of emotion by text analysis using machine learning. 2023. 14, <https://www.doi.org/10.3389/fpsyg.2023.1190326>
- Salem, I.E., Al-Saedi, K.H.: Intensive Malware detection approach based on data mining. 2023. *Journal of Applied Engineering and Technological Science*, 5, 414-424. <https://www.doi.org/10.37385/jaets.v5i1.2865>
- Kubanyi, J., Hlavac, P., Simko, J., Bielikova, M.: Towards Automated Web Navigation and Search Skill Assessment: An Eye-tracking Study on the Skill Differences. 2018. In: *13th International Workshop on Semantic and Social Media Adaptation and Personalization*, pp. 49-54. <https://www.doi.org/10.1109/SMAP.2018.8501883>
- Savannah Wei Shi, Trusov, M.: The Path to Click: Are You on It? 2020. *Marketing Science*, 40, 344-365. <https://doi.org/10.1287/mksc.2020.1253>
- Kimjo, H., Mbaitiga, Z.: Development of flexible Text Input Device Based on Image Processing for Each Level of Disability Person. 2022. In: *ICIIBMS 2022 - 7th International Conference on Intelligent Informatics and Biomedical Sciences*, pp. 378-379. <https://www.doi.org/10.1109/ICIIBMS55689.2022.9971506>
- Iqbal, M.W., Ch, N.A., Shahzad, S.K., Naqvi, M.R., Khan, B.A., Ali, Z.: User Context Ontology for Adaptive Mobile-Phone Interfaces. 2021. *IEEE Access*, 9, 96751-96762. <https://www.doi.org/10.1109/ACCESS.2021.3095300>
- Dumitrescu, A., Santini, S.: Full coverage of a reader's interests in context-based information filtering. 2021. *Journal of the Association for Information Science Technology*, 72, 1011-1027. <https://doi.org/10.1002/asi.24470>
- Sun, B., Mao, H., Yin, C.: Male and Female Users' Differences in Online Technology Community Based on Text Mining. 2020. 11, <https://www.doi.org/10.3389/fpsyg.2020.00806>
- Rybaczewska, M., Sparks, L.: Ageing consumers and e-commerce activities. 2022. *Ageing and Society*, 42, 1879-1898. <https://www.doi.org/10.1017/S0144686X20001932>
- Jin, Y., Tintarev, N., Htun, N.N., Verbert, K.: Effects of personal characteristics in control-oriented user interfaces for music recommender systems. 2020. *User Modeling and User-Adapted Interaction*, 30, 199-249. <https://doi.org/10.1007/s11257-019-09247-2>
- Vandic, D., Nesterstigt, L.J., Frasincar, F., Kaymak, U., Ido, E.: A framework for approximate product search using faceted navigation and user preference ranking. 2024. *Data and Knowledge Engineering*, 149, <https://www.doi.org/10.1016/j.datak.2023.102241>
- Oukfif, K., Battou, F., Bouzeffrane, S.: Budget-Aware Performance Optimization of Workflows in Multiple Data Center Clouds. 2020. pp. 144-160. https://www.doi.org/10.1007/978-3-030-67550-9_10
- Sandoval-Gaytan, B.D., Camacho, L.-M., Hurtado, C.V.: Point Cloud Generation of Transparent Objects: A Comparison between Technologies. 2023. pp. 1-3. <https://www.doi.org/10.1109/EDUCON54358.2023.10125143>