

R&I

IN3
Internet
Interdisciplinary
Institute

research.uoc.edu



Arquitectura para la Detección de Noticias Falsas Basada en *Watermarking y Machine Learning*



XVII Reunión Española de Criptología y Seguridad de la Información (RECSI 2022)
Santander, octubre de 2022

Victor Garcia-Font, Tanya Koochpayeharaghi, David Megías, Helena Rifà, Julián Salas, Jordi Serra-Ruiz
Internet Interdisciplinary Institute (IN3), Universitat Oberta de Catalunya

Índice

1. Introducción
 2. Tecnologías
 3. Metodología y arquitectura
 4. Retos de investigación
 5. Resumen y trabajo futuro
-



R&I

IN3
Internet
Interdisciplinary
Institute

research.uoc.edu

1

Introducción

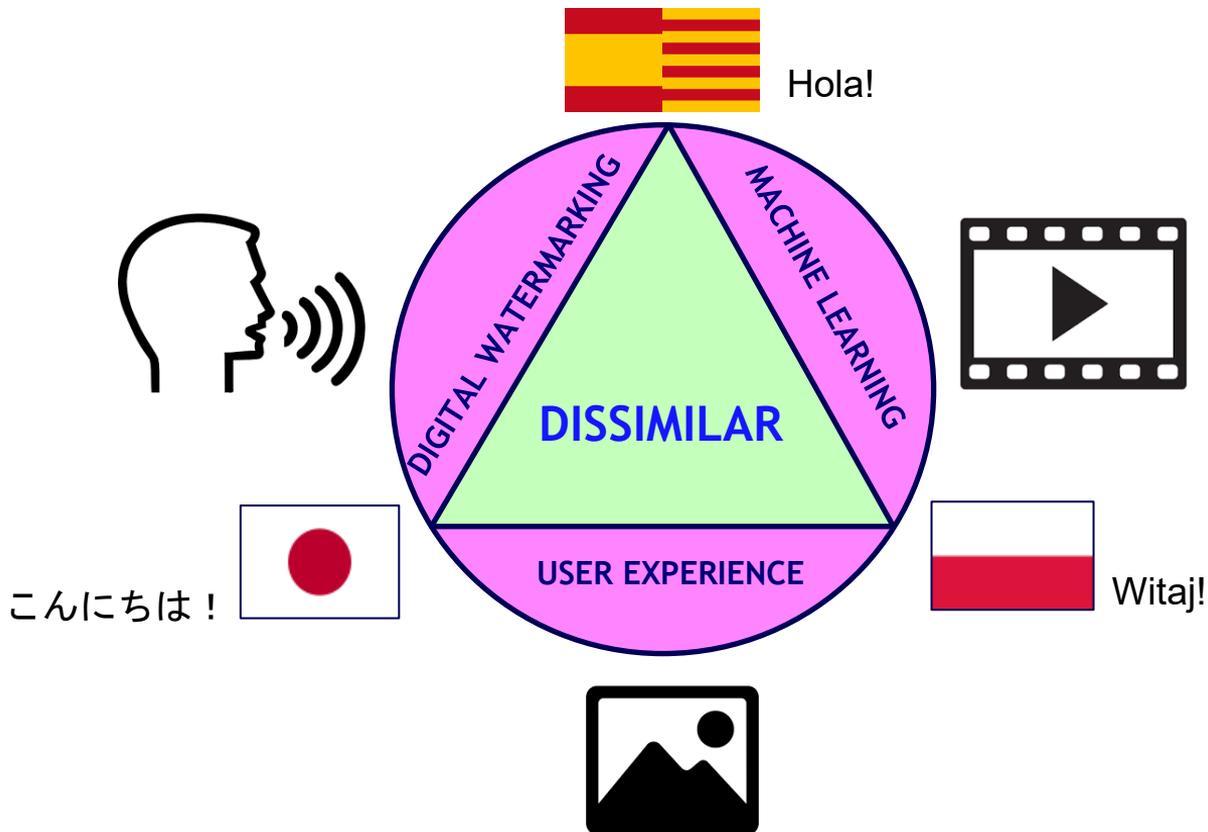
1. Introducción



- Los líderes de opinión en línea tienen una gran influencia en las comunidades en línea, ¡a veces basándose en **noticias falsas!**
- La difusión de rumores o de noticias falsas se han visto reforzadas con la **creciente relevancia de las redes sociales** online y la popularización de la cultura participativa.
- **Las marcas de agua digitales** se reconocen como una técnica prometedora desarrollada para abordar los problemas de protección de derechos de autor, autenticación de contenidos o detección de manipulaciones, entre otros.

1. Introducción

- ✓ Interdisciplinario
- ✓ Internacional e intercultural
- ✓ Plurilingüe
- ✓ Múltiples formatos multimedia





R&I

IN3
Internet
Interdisciplinary
Institute

research.uoc.edu

2

Tecnologías

2. Tecnologías – Watermarking digital



Luis (liamngls)

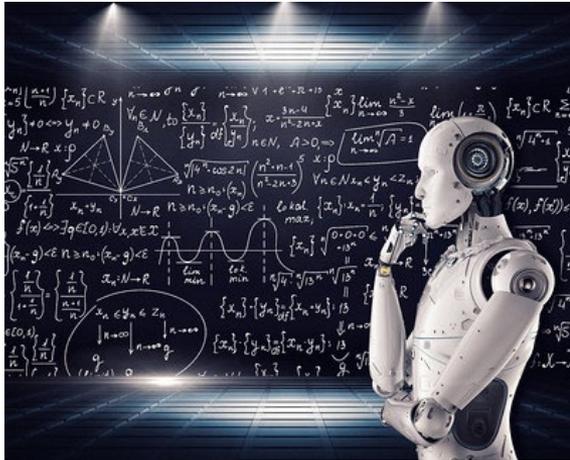
- Entre las aplicaciones del *watermarking* digital, la **prueba de propiedad / identificación del propietario, el seguimiento de transacciones y la detección de manipulaciones** son las más relevantes.
- Combinación de diferentes enfoques: **marcas de agua robustas** para la prueba de propiedad y el seguimiento de transacciones, y **marcas de agua frágiles o semifrágiles** para la detección y localización de manipulaciones → **Escenario novedoso.**
- Diferentes tipos de marcas de agua → **diversidad de requisitos y mayor complejidad.**
- Diferentes tipos de contenido multimedia (imagen, voz y vídeo).

2. Tecnologías – Técnicas forenses para multimedia



- Tecnologías destinadas a revelar la historia de los contenidos: **identificación del dispositivo de adquisición, validación de la integridad de los contenidos, recuperación de información de las señales en los contenidos.**
- Un dispositivo de adquisición deja huellas específicas debido a sus características intrínsecas: **distorsión causada por el hardware.**
- **Las operaciones de manipulación de contenidos multimedia dejan distorsiones** causadas por la operación de procesamiento de señales en el software: **distorsión causada por el software.**
- Con la ayuda de técnicas de **aprendizaje profundo**, podemos detectar tales distorsiones y clasificar rastros de edición maliciosos en contenidos multimedia.

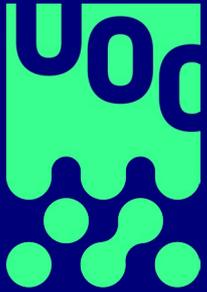
2. Tecnologías: detección basada en aprendizaje automático



Mike MacKenzie

<https://www.vpnsrus.com>

- Clasificación de contenidos falsos → **extraer características** de un contenido objetivo y un **algoritmo de ML** calcula una métrica para decidir si las características pertenecen a una clase positiva o negativa.
- Dos pasos: **extracción de características y selección de características.**
- El uso de **aprendizaje profundo** permite la extracción automática de características.
- Las **redes neuronales recurrentes (RNN)** y las **redes neuronales convolucionales (CNN)** son la base de muchas técnicas.
- Se han propuesto varias soluciones para la detección de rostros y voz generados artificialmente.



R&I

IN3
Internet
Interdisciplinary
Institute

research.uoc.edu

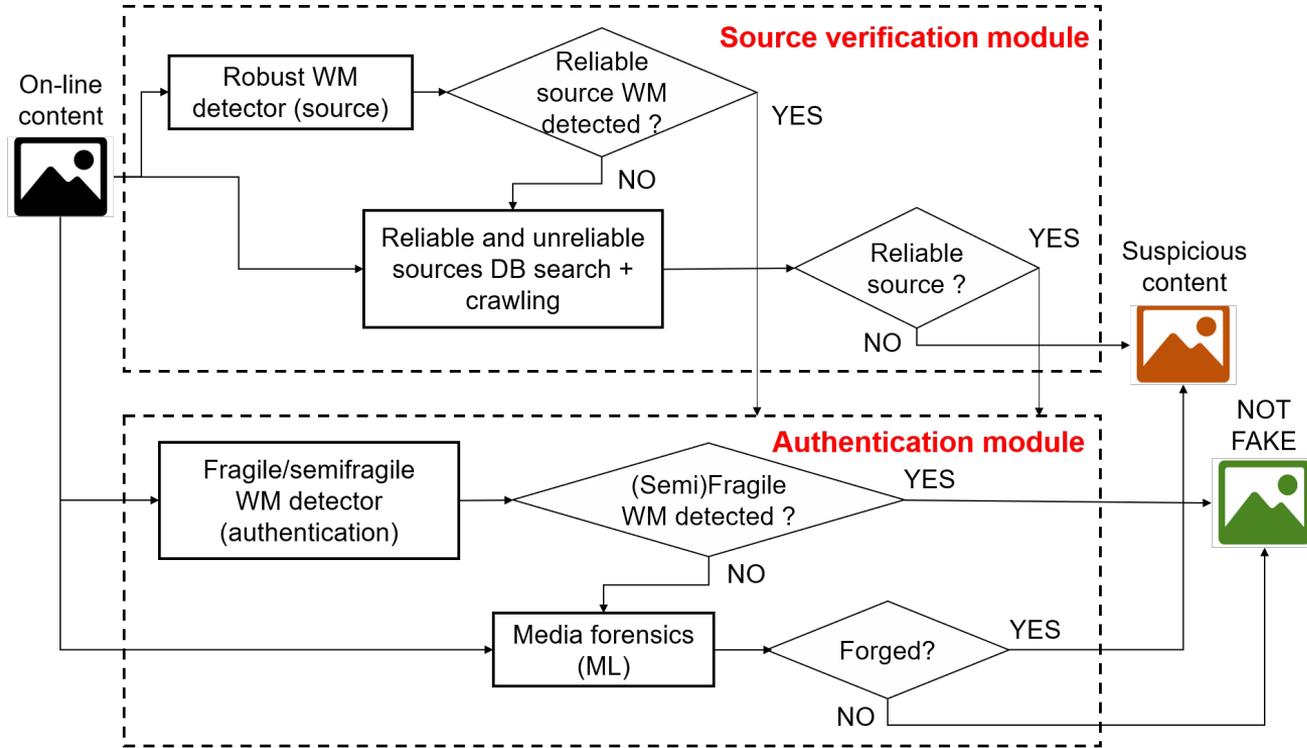
3

Metodología y arquitectura

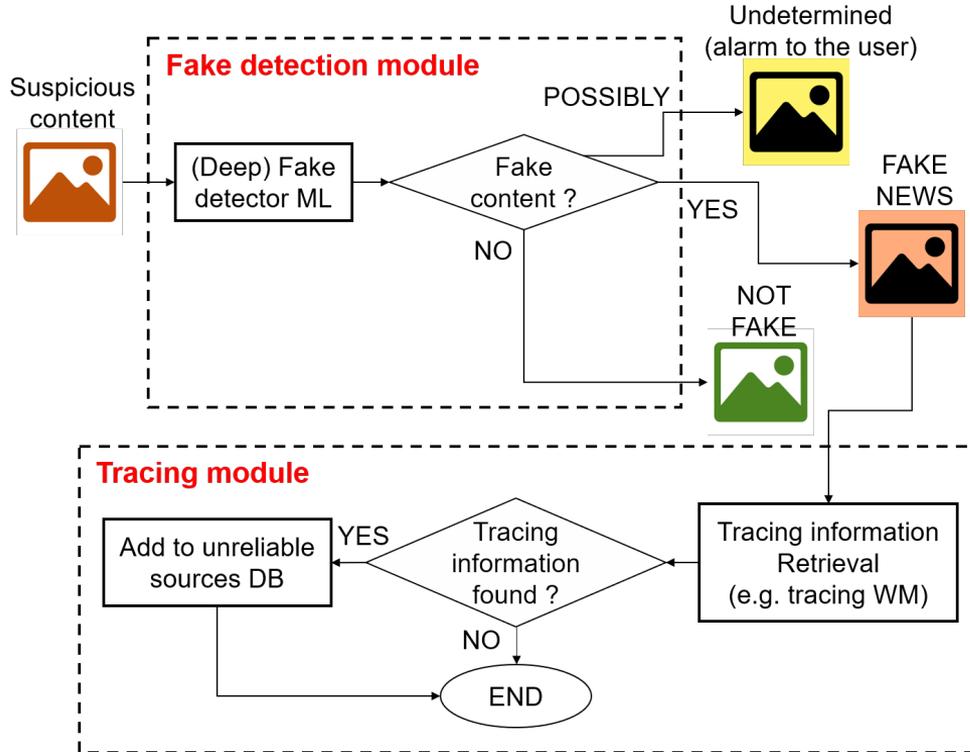
3. Metodología

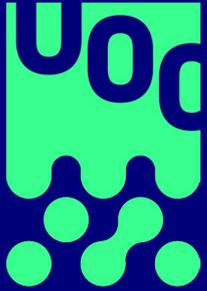
- El proyecto se divide en tres fases diferentes:
 - Fase 1: **Diseño e implementación de herramientas de watermarking**
Selección e implementación de las soluciones de marca de agua para crear un sistema de prueba de concepto que será evaluada empíricamente.
 - Fase 2: **Diseño e implementación de herramientas de detección**
Diseño e implementación de Redes Neuronales Profundas (DNN) para la identificación de contenidos falsos.
 - Fase 3: **Estudio de la experiencia del usuario**
Focus groups para una mejor comprensión de los factores culturales involucrados en la difusión de noticias falsas y pruebas de evaluación heurística y usabilidad que combinan datos cualitativos y cuantitativos para el prototipado de la herramienta.

3. Arquitectura



3. Arquitectura





R&I

IN3
Internet
Interdisciplinary
Institute

research.uoc.edu

4

Retos de investigación

4. Retos de investigación

Distributed, Automated Web Page Harvesting Platform for Large-scale Analysis of Digital Media

The developed harvesting platform is structured as a modular system designed to perform **two main functions**:

- Web page harvesting to obtain digital multimedia content, and
- Analyzing the downloaded content with various analytical tools to detect fake news and other anomalies

The screenshot shows the 'Flower System Status Overview' dashboard. It features a navigation sidebar on the left with sections for System, Tasks Setup, File Management, and DB Management. The main content area displays a summary of system statistics and a table of worker performance.

System Status Overview

Flower | [Dashboard](#) | [Tasks](#) | [Tracker](#) | [Docs](#) | [Code](#)

Active: 23 | Processed: 104213 | Failed: 0 | Succeeded: 104163 | Retried: 0

Worker Name	Status	Active	Processed	Failed	Succeeded	Retried	Load Average
harvester0@node0	Online	17	589	0	503	0	0.89, 1.06, 1.03
analyzer@node1	Online	6	103639	0	103614	0	19.8, 21.74, 21.13

Showing 1 to 2 of 2 entries

4. Retos de investigación

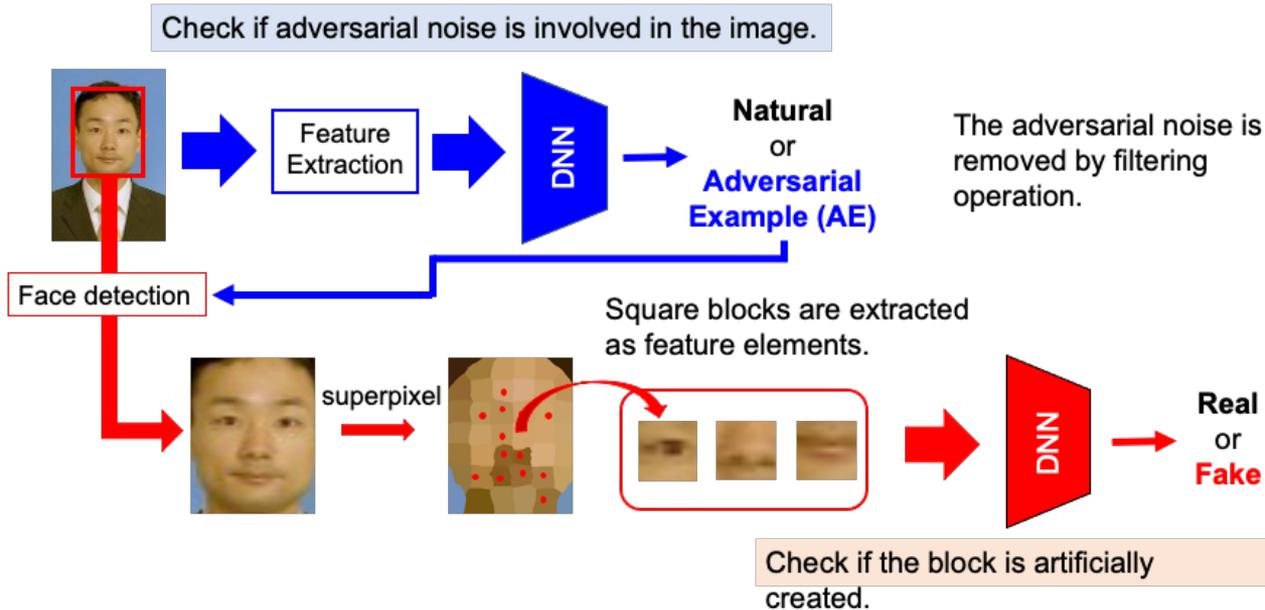
Implementación y combinación de **herramientas de watermarking** para tres tareas diferentes:

1. **Verificación de contenido legítimo** proveniente de fuentes reconocidas
2. **Detección de manipulación maliciosa** e intencionada de contenidos
3. **Trazabilidad** de contenidos detectados como falsos

4. Retos de investigación

Detection of Fake Contents

Two-stage classification architecture for detecting fake contents.





R&I

IN3
Internet
Interdisciplinary
Institute

research.uoc.edu

5

Resumen y trabajo futuro



5. Resumen y trabajo futuro

- **DISSIMILAR es un proyecto internacional en curso** llevado a cabo por tres socios de España, Japón y Polonia.
- El objetivo principal es **desarrollar herramientas**, basadas en marcas de agua digitales y ML, **que permitan la detección de noticias falsas en las plataformas de redes sociales.**
- Se está realizando un estudio de **experiencia del usuario** para proporcionar implicaciones para el diseño, la implementación, la integración y la evaluación de las herramientas, sobre la base de las experiencias de diversos usuarios potenciales.
- También queremos **atraer más investigación de diferentes comunidades académicas** para afrontar el desafío de reducir el impacto y la redistribución de las noticias falsas.



5. Resumen y trabajo futuro

- Proponemos una **estrategia interdisciplinaria** para abordar el problema que incluye ocultación de datos, ML, análisis forense multimedia y tener en cuenta los factores sociales y culturales.
- Se espera obtener **un prototipo** que combine todas estas herramientas y conocimientos sobre el comportamiento de los usuarios y que sea más exitoso que las soluciones parciales por sí solas.



Véronique Debord-Lazaro

 UOCresearch
 @UOC_research

¡¡Muchas gracias!!

<http://dissimilar.ii.pw.edu.pl/>