

Verificación automática de presentaciones usando inteligencia artificial

Raul Bautista Arroyo¹, Jorge de la Calleja¹,
Marco Aurelio Nuño Maganda²,
María Auxilio Medina Nieto¹

¹ Universidad Politécnica de Puebla,
Mexico

² Universidad Politécnica de Victoria,
Mexico

{raul.bautistaao, maria.medina,
jorge.delacalleja}@uppuebla.edu.mx,
mnunom@upv.edu.mx

Resumen. Este trabajo presenta los primeros resultados de una investigación sobre el desarrollo de una herramienta basada en aprendizaje automático para la verificación automática de presentaciones en formato PDF. Se han realizado experimentaciones con cuatro algoritmos supervisados: Naïve Bayes, árboles de decisión, redes neuronales y Máquinas de Soporte Vectorial (SVM); y se aplicó el algoritmo de Análisis de Componentes Principales (PCA) para extraer los atributos más relevantes y reducir la dimensionalidad. Los datos fueron transformados en matrices de atributos y evaluados utilizando el 100 %, 70 % y 50 % de los atributos. Los resultados preliminares indican que las redes neuronales lograron la mayor precisión y F-measure, incluso con una reducción significativa de atributos. Esta investigación representa un avance hacia la automatización de la evaluación de presentaciones, facilitando la identificación de inconsistencias y mejorando el proceso de revisión documental.

Palabras clave: Aprendizaje automático, verificación de presentaciones, redes neuronales, clasificación de documentos, inteligencia artificial.

Automatic Verification of Presentations Using Artificial Intelligence

Abstract. This work presents the initial results of a research project on the development of a machine learning-based tool for the automatic verification of PDF submissions. Experiments were carried out with four supervised algorithms: Naïve Bayes, decision trees, neural networks, and Support Vector Machines (SVMs); and the Principal Component Analysis (PCA) algorithm was applied to extract the most relevant attributes and reduce dimensionality. The data were transformed into attribute matrices and evaluated using 100%, 70%, and 50% of the

attributes. Preliminary results indicate that the neural networks achieved the highest accuracy and F-measure, even with a significant reduction in attributes. This research represents a step toward automating submission evaluation, facilitating the identification of inconsistencies and improving the document review process.

Keywords: Machine learning, presentation verification, neural networks, document classification, artificial intelligence.

1. Introducción

La inteligencia artificial (IA) ha demostrado ser una herramienta útil para resolver problemas complejos en diversos dominios, incluyendo la medicina, la industria, el comercio y la educación. El aprendizaje automático supervisado ha permitido automatizar tareas que anteriormente requerían intervención humana intensiva como la clasificación, predicción o detección de patrones.

En este contexto, una problemática que puede ser interesante y relevante es la verificación del cumplimiento de lineamientos en presentaciones empresariales y educativas, tarea que comúnmente se realiza de forma manual, con un alto grado de subjetividad y consumo de tiempo. El problema de clasificación abordado en esta investigación consiste en identificar, a partir de cada diapositiva convertida en imagen, si cumple o no con un lineamiento predefinido.

La función objetivo es minimizar el tiempo que una persona requiere para validar el cumplimiento de lineamientos en presentaciones, asegurando una evaluación objetiva y detallada sobre cada diapositiva. Cada presentación es analizada diapositiva por diapositiva, se evalúan elementos visuales como texto, imágenes, tablas y estructuras gráficas.

Los lineamientos establecidos son los siguientes: (1) Cada diapositiva debe presentar información coherente con su título (por ejemplo, si el título dice “Endpoints”, deben mostrarse los endpoints analizados); (2) La primera mitad de la presentación debe enfocarse en describir activos de TI, su relación y su criticidad operativa; (3) La segunda mitad presenta los resultados del análisis de seguridad, describiendo riesgos encontrados, falsos positivos y controles recomendados.

Dentro de las presentaciones de las organizaciones e instituciones, hoy en día existen lineamientos que deben de cumplirse para garantizar que los objetivos y los temas relacionados a los mismos se cumplan, en las Figuras 1.1 y 1.2 muestran algunos ejemplos de los lineamientos que se piden para una presentación de análisis de seguridad de una empresa multinacional, tales como describir el objetivo general de la presentación, los miembros que participaron en el análisis, algunas métricas asociadas a la presentación, el mapeo técnico de las aplicaciones involucradas en el proyecto, las aplicaciones relacionadas y las gestiones de accesos involucradas.

En este trabajo de investigación, en desarrollo, se utilizaron cuatro algoritmos de aprendizaje automático supervisado: Naïve Bayes, árboles de decisión, redes neuronales y máquinas de soporte vectorial (SVM). Estos algoritmos fueron seleccionados por su efectividad comprobada en diversas tareas de clasificación y su capacidad para manejar datos de alta dimensionalidad.

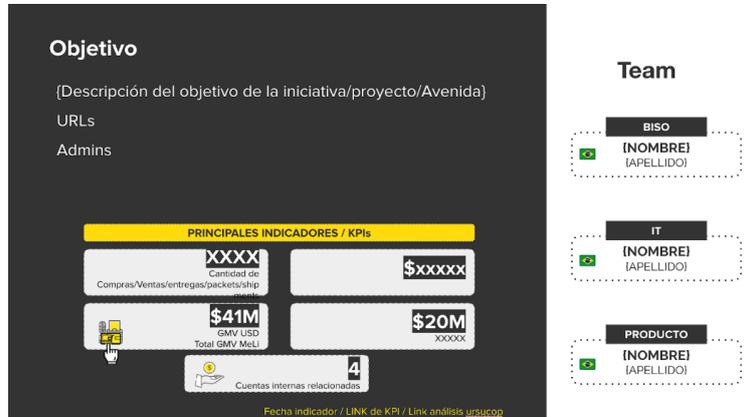


Fig. 1. Lineamientos de presentaciones donde se solicitan objetivos, métricas y colaboradores participantes.

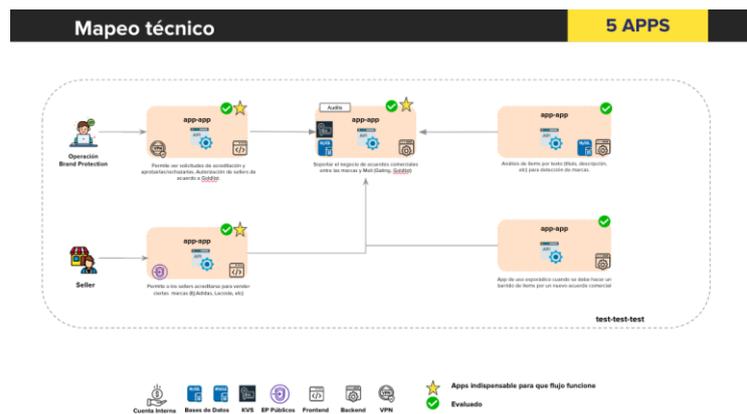


Fig. 2. Lineamientos de presentaciones donde se mapea la relación de las aplicaciones y la importancia de las mismas en un flujo de negocio.

2. Trabajos relacionados

Para identificar investigaciones previas, se realizó una búsqueda en bases de datos como IEEE, Springer, ScienceDirect y MDPI. Enseguida se mencionan de manera breve algunos de los trabajos más relevantes, los cuales han sido clasificados de acuerdo al problema, los algoritmos utilizados y por selección de atributos:

- **Justificación del problema:** Roy y Daniel [3] estudiaron herramientas digitales en la creación y revisión de presentaciones, destacando la necesidad de automatizar procesos de validación. Bueno y Esquivel [4], y Abrancato y Welsh [5] enfatizaron

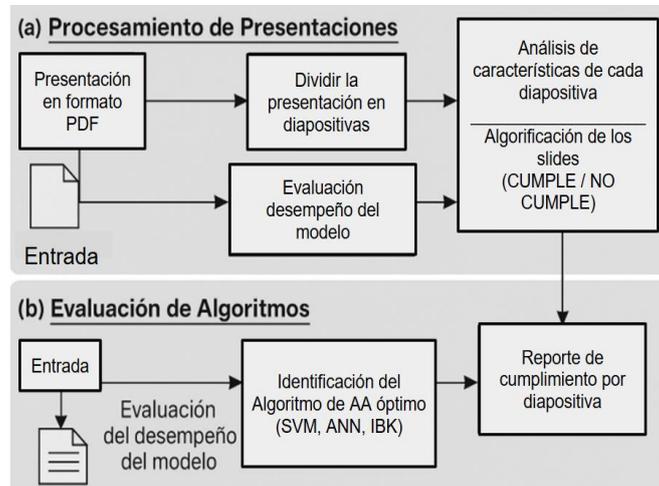


Fig. 1.3. Mapa de solución propuesta para esta investigación donde con ayuda de algoritmos de aprendizaje automático se busca analizar el cumplimiento de los lineamientos en las presentaciones.

la importancia de la digitalización de procesos administrativos, incluyendo la revisión documental.

- **Algoritmos de aprendizaje automático:** Idrissi [6] y Mahadevkar et al. [7] exploraron aplicaciones de redes neuronales y SVM en tareas de validación automática. Hussain [8] destacó la aplicación de modelos de visión por computadora en la Industria 4.0.
- **Selección y reducción de atributos:** Zhou et al. [1] propusieron la selección de características basada en árboles de decisión. Borade y Netak [9] utilizaron SVM para calificar diapositivas, mientras que Chen et al. [11] integraron pistas multimodales para evaluar presentaciones.

3. Metodología y métodos

La figura 1.3 muestra el flujo general del proceso para evaluar presentaciones mediante algoritmos de aprendizaje automático, desde la conversión del archivo original hasta la generación de un reporte con los resultados del análisis. Esto es, las presentaciones se reciben en formato PDF y se convierten en imágenes .png. Posteriormente, se realiza la clasificación binaria de cada diapositiva (cumple/no cumple) mediante algoritmos de aprendizaje automático y evaluando el desempeño con distintas cantidades de atributos usando PCA.

3.1. Etapas de la metodología

Enseguida se describen los pasos que se siguieron en la metodología:

3.1.1. Conversión de la presentación a imágenes

Para asegurar la portabilidad y compatibilidad del contenido, las presentaciones se reciben en formato PDF. Posteriormente, se realiza un proceso de conversión que divide el archivo por diapositiva y transforma cada una en una imagen .png. Esta transformación facilita el procesamiento por parte de los algoritmos de aprendizaje automático.

3.1.2. Clasificación de diapositivas mediante aprendizaje automático

Una vez convertidas en imágenes, las diapositivas son analizadas por algoritmos de aprendizaje automático supervisado. Estos algoritmos —Support Vector Machine (SVM), Redes Neuronales (ANN) e k-vecinos más cercanos (IBK)— tienen como objetivo clasificar cada diapositiva, determinando si cumple o no con los lineamientos de formato previamente definidos.

3.1.3. Validación de cumplimiento de lineamientos

Tras la clasificación, cada diapositiva es evaluada para verificar si cumple con los lineamientos esperados (como estructura, contenido mínimo, uso correcto de elementos visuales, etc.). El resultado de esta validación es binario que indica true si cumple o false si no cumple.

3.1.4. Evaluación comparativa de algoritmos

Se realiza una evaluación comparativa entre los algoritmos utilizados (SVM, ANN, IBK), con el objetivo de identificar cuál de ellos ofrece el mejor rendimiento para la tarea de verificación. La evaluación considera métricas como la precisión, exactitud y capacidad de generalización a nuevas presentaciones.

3.1.5. Generación de reporte automatizado

Finalmente, con base en los resultados del modelo de AA, se genera un reporte automatizado en formato Excel. Este reporte incluye:

- Las diapositivas que cumplen y no cumplen con los lineamientos.
- Detalles específicos de los puntos faltantes por cada diapositiva.
- Un porcentaje de avance o cumplimiento general de la presentación.

La metodología descrita permite automatizar la verificación del cumplimiento de lineamientos en presentaciones digitales mediante el uso de algoritmos de aprendizaje automático y procesamiento de imágenes. Este enfoque no solo reduce la carga de trabajo manual, sino que también proporciona resultados objetivos y reproducibles.

3.2. Algoritmos de aprendizaje automático

En este trabajo se utilizaron tres algoritmos de aprendizaje automático supervisado: Máquinas de Vectores de Soporte (SVM), Redes Neuronales Artificiales (ANN) y k-vecinos más cercanos (IBk). Estos modelos fueron seleccionados por su efectividad en tareas de clasificación y su capacidad para manejar datos con alta dimensionalidad.

- **SVM:** Encuentra el mejor límite de separación entre clases, siendo eficaz en espacios con muchos atributos.
- **ANN:** Aprende patrones complejos mediante una red de nodos conectados, ideal para datos visuales.
- **IBk:** Clasifica según los ejemplos más cercanos, siendo simple y eficaz en problemas bien definidos.

Cada algoritmo fue evaluado utilizando el conjunto de datos original y versiones reducidas mediante PCA, con el objetivo de determinar cuál ofrece la mayor precisión en la verificación automática de presentaciones.

4. Resultados experimentales

Para llevar a cabo los experimentos, se utilizaron implementaciones de algoritmos de aprendizaje automático proporcionadas por la biblioteca scikit-learn en Python. También se emplearon otras herramientas como *Pandas* para el manejo de datos, *Seaborn* y *Matplotlib* para la visualización de resultados, y *Joblib* para guardar los modelos entrenados. El proceso de entrenamiento, evaluación y generación de métricas se realizó en un entorno de experimentación, permitiendo que los experimentos puedan ser replicables por otros investigadores.

El conjunto de datos está compuesto por 648 instancias de 112 presentaciones, esto se logra por medio de la carga de las imágenes de las diapositivas, se convierten a escala de grises y se normalizan a un tamaño fijo de 128x128 píxeles lo cual nos dará como resultado una matriz de 16385 atributos. Posteriormente, cada imagen se convierte en un vector de atributos (píxeles) y se le asigna una etiqueta de clase. Estos vectores y etiquetas se organizan en un *DataFrame* y se guardan en un archivo CSV donde se organizan en un total de 34 clases que corresponden a:

✓OK, cuando una diapositiva cumple con los componentes que caracterizan su lineamiento:

- Detalles caso de abuso exitoso ok
- Frontend relacionados ok
- Mapeo técnico ok
- Diapositiva título hallazgo ok
- Proveedores ok
- Credenciales hardcodeadas ok
- Diapositiva 2 ok
- Imágenes frontend ok
- Análisis overview ok
- Casos de uso y abuso ok
- Access group ok
- Secrets ok
- Objetivo ok

- Diapositiva títulos anexos ok
- Hallazgos ok
- Bases de datos ok
- Diapositiva título resumen ok
- Histórico vulnerabilidades ok
- Flujo feliz ok
- Diapositiva 1 ok

✓Error, cuando una diapositiva no cumple con los componentes que caracterizan a la diapositiva de su lineamiento

- Diapositiva links documentación error
- Credenciales hardcodeadas error
- Gracias error
- Object storage error
- Diapositivas vacíos error
- Detalles caso de abuso exitoso error
- Access group error
- Bases de datos error
- Imágenes frontend error
- Objetivo error
- Proveedores error
- Kvs error
- Gestión de accesos admin error
- Mapeo técnico error

Los anteriores representan a las clases que ayudan a identificar si las diapositivas cumplen con lineamientos descritos en la Sección 2. Las imágenes de las diapositivas usadas en esta investigación fueron convertidas en vectores de características, dando como resultado una matriz con 16,385 atributos. Debido a la alta dimensionalidad, se aplicó una técnica de reducción de atributos mediante el algoritmo PCA (Análisis de Componentes Principales). Esta técnica permite conservar la mayor cantidad de información posible mientras se reducen los atributos, con el objetivo de disminuir la carga computacional y mejorar el desempeño de los modelos. En este estudio se compararon los resultados utilizando el 100 %, 70 % y 50 % de los atributos originales, seleccionados con base en los niveles de varianza explicada acumulada generados por PCA.

Se evaluaron cuatro algoritmos de aprendizaje automático en distintas configuraciones: Naïve Bayes, Árboles de Decisión, Redes Neuronales y Máquinas de

Tabla 1. Evaluación de algoritmos de aprendizaje automático donde se obtuvo el mejor rendimiento usando diferentes cantidades de atributos.

Algoritmo	Precisión	F-Measure	% Atributos Usados	# Instancias	# Atributos
Naïve Bayes	0.77	0.76	100 %	648	16,385
Naïve Bayes	0.76	0.75	70 %	648	11,469
Naïve Bayes	0.77	0.76	50 %	648	8,192
Árboles de Decisión	0.84	0.80	100 %	648	16,385
Árboles de Decisión	0.76	0.76	70 %	648	11,469
Árboles de Decisión	0.73	0.73	50 %	648	8,192
Redes Neuronales (ANN)	0.86	0.85	100 %	648	16,385
Redes Neuronales (ANN)	0.75	0.76	70 %	648	11,469
Redes Neuronales (ANN)	0.81	0.80	50 %	648	8,192
Máquinas de Vectores de Soporte (SVM)	0.84	0.82	100 %	648	16,385
Máquinas de Vectores de Soporte (SVM)	0.56	0.60	70 %	648	11,469
Máquinas de Vectores de Soporte (SVM)	0.60	0.64	50 %	648	8,192

Tabla 2. Evaluación de Algoritmos de Aprendizaje Automático donde se obtuvo el mejor rendimiento usando diferentes cantidades de atributos.

Algoritmo	Precisión	Medida -F	% de Atributos usados
Naïve Bayes	0.77	0.76	100 %
Árboles de Decisión	0.84	0.80	100 %
Redes Neuronales	0.86	0.85	50 %
SVM	0.84	0.82	70 %

Vectores de Soporte. Cada uno fue probado en tres condiciones diferentes (con 100 %, 70 % y 50 % de atributos), y los resultados de precisión y F-measure fueron promediados. La Tabla 1 muestra los mejores resultados obtenidos por cada algoritmo según el porcentaje de atributos usados:

La Tabla 1 muestra los resultados de las pruebas realizadas sobre los algoritmos de aprendizaje automático evaluados en esta investigación: Naïve Bayes, Árboles de

parámetros puede mejorar el rendimiento de los modelos, tanto en precisión como en eficiencia.

La Figura 1.4 muestra la matriz de confusión correspondiente al modelo de Red Neuronal Artificial (ANN) entrenado para verificar automáticamente el cumplimiento de lineamientos en presentaciones. Esta matriz representa el rendimiento del modelo en la clasificación de cada diapositiva dentro de una de las 34 clases posibles, donde cada clase corresponde a un tipo específico de diapositiva o lineamiento evaluado (por ejemplo: “objetivo”, “endpoints”, “credenciales hardcodeadas”, entre otros).

En la matriz, el eje vertical representa las clases reales y el eje horizontal las clases. Los valores en la diagonal indican predicciones correctas (donde la clase real coincide), mientras que los valores fuera de la diagonal reflejan errores de clasificación.

El modelo logra una concentración significativa de valores en la diagonal, lo cual indica alto nivel de precisión en la clasificación multiclase, especialmente considerando la alta dimensionalidad del conjunto de datos (16,385 atributos originales reducidos mediante PCA). La matriz evidencia que el modelo fue capaz de identificar correctamente múltiples clases, incluso bajo el esquema de evaluación binaria por cumplimiento y utilizando reducción de atributos al 50 %, lo cual refuerza su capacidad de generalización y eficiencia en contextos reales.

5. Conclusiones

La evaluación de los algoritmos de aprendizaje automático permitió identificar que las redes neuronales ofrecieron el mejor desempeño en la tarea de verificación de presentaciones, logrando una precisión del 86 % y F-measure del 85 % incluso con una matriz reducida al 50 % de los atributos. Esto resalta su capacidad para generalizar patrones relevantes aun cuando se trabaja con menos información. En función del objetivo planteado, se logró comparar el rendimiento de distintos algoritmos y establecer cuál resulta más adecuado. Aunque el trabajo se encuentra en una etapa experimental, ya se han obtenido avances significativos. Como trabajo futuro, se contempla continuar con la validación del modelo de redes neuronales en entornos reales.

Referencias

1. Zhou, H.F., Zhang, J.W., Lu, Y.: A Feature Selection Algorithm of Decision Trees. *Journal of Computer Science and Technology*, 35(6), pp. 1301–1315.6 (2020) doi: 10.1016/j.eswa.2020.113842.
2. Recio, J.A.: Técnicas de extracción de características y clasificación en ortoimágenes. *Revista de Geografía y Sistemas de Información Geográfica*, 1(2), pp. 45–60 (2009)
3. Roy S., Daniel, C.: Introducción a las aplicaciones de presentación. *University of Science and Technology Journal*, 12(1), pp. 78–85 (2023)
4. Bueno E.H., Esquivel, P.L.: Desarrollo de la gestión documental. *Journal of Management and Business Administration*, 19(3), pp. 233–250 (2011)
5. Abrancato, A.G., Welsh, V.: Transformación digital y eficiencia: Digitalización de procesos administrativos. *Journal of Business Innovation*, 8(4), pp. 112–126 (2021)

6. Idrissi, I.E.: Error-Correcting Codes and The Power of Machine Learning. *IEEE Transactions on Information Theory*, 70(5), pp. 1234–1248 (2024) doi: 10.1109/SITA60746.2023.10373727.
7. Mahadevkar, S.V., Khemani, B., Gurnani, S.: A Review on Machine Learning Styles in Computer Vision. *International Journal of Computer Vision*, 130(3), pp. 567–589 (2022) doi: 10.1109/ACCESS.2022.3209825.
8. Hussain, M.: Sustainable Machine Vision for Industry 4.0. *MDPI Sustainability*, 16(2), pp. 345–360 (2024) doi: 10.3390/ai5030064.
9. Borade, J.G., Netak, L.D.: Machine learning techniques for grading of powerpoint diapositivas. In: *Proceedings of the International Conference on Machine Learning and Applications*, pp. 234–240 (2022) doi: 10.1007/978-3-030-98404-5_1.
10. Borade, J.G., Kiwelekar, A.W., Netak, L.D.: Automated Grading of Powerpoint Presentations Using Latent Semantic Analysis. *IEEE Access*, 9, pp. 123456–123465 (2021) doi: 10.18280/ria.360215
11. Chen, L., Leong, C.W., Feng, G.: Using Multimodal Cues to Analyze MLA'14 Oral Presentation Quality Corpus: Presentation Delivery and Diapositivas Quality. In: *Proceedings of the 2014 ACM Workshop on Multimodal Learning Analytics Workshop and Grand Challenge*, pp. 45–52 (2014) doi: doi.org/10.1145/2666633.2666664.