

EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



Instituto Politécnico Nacional
"La Técnica al Servicio de la Patria"

Research in Computing Science

Vol. 153 No. 3
March 2024

Research in Computing Science

Series Editorial Board

Editors-in-Chief:

*Grigori Sidorov, CIC-IPN, Mexico
Gerhard X. Ritter, University of Florida, USA
Jean Serra, Ecole des Mines de Paris, France
Ulises Cortés, UPC, Barcelona, Spain*

*Jesús Angulo, Ecole des Mines de Paris, France
Jihad El-Sana, Ben-Gurion Univ. of the Negev, Israel
Alexander Gelbukh, CIC-IPN, Mexico
Ioannis Kakadiaris, University of Houston, USA
Petros Maragos, Nat. Tech. Univ. of Athens, Greece
Julian Padget, University of Bath, UK
Mateo Valero, UPC, Barcelona, Spain
Olga Kolesnikova, ESCOM-IPN, Mexico
Rafael Guzmán, Univ. of Guanajuato, Mexico
Juan Manuel Torres Moreno, U. of Avignon, France
Miguel González-Mendoza, ITESM, Mexico*

Associate Editors:

Editorial Coordination:

Griselda Franco Sánchez

Research in Computing Science, Año 23, Volumen 153, No. 3, marzo de 2024, es una publicación mensual, editada por el Instituto Politécnico Nacional, a través del Centro de Investigación en Computación. Av. Juan de Dios Bátiz S/N, Esq. Av. Miguel Othon de Mendizábal, Col. Nueva Industrial Vallejo, C.P. 07738, Ciudad de México, Tel. 57 29 60 00, ext. 56571. <https://www.rcs.cic.ipn.mx>. Editor responsable: Dr. Grigori Sidorov. Reserva de Derechos al Uso Exclusivo del Título No. 04-2019-082310242100-203. ISSN: en trámite, ambos otorgados por el Instituto Politécnico Nacional de Derecho de Autor. Responsable de la última actualización de este número: el Centro de Investigación en Computación, Dr. Grigori Sidorov, Av. Juan de Dios Bátiz S/N, Esq. Av. Miguel Othon de Mendizábal, Col. Nueva Industrial Vallejo, C.P. 07738. Fecha de última modificación 01 de enero de 2024.

Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación.

Queda estrictamente prohibida la reproducción total o parcial de los contenidos e imágenes de la publicación sin previa autorización del Instituto Politécnico Nacional.

Research in Computing Science, year 23, Volume 153, No. 3, March 2024, is published monthly by the Center for Computing Research of IPN.

The opinions expressed by the authors does not necessarily reflect the editor's posture.

All rights reserved. No part of this publication may be reproduced, stored in a retrieval system, or transmitted, in any form or by any means, electronic, mechanical, photocopying, recording or otherwise, without prior permission of Centre for Computing Research of the IPN.

Computing Applications in Modern Industry

Teodoro Córdova Fraga (ed.)



**Instituto Politécnico Nacional
“La Técnica al Servicio de la Patria”**



**Instituto Politécnico Nacional, Centro de Investigación en Computación
México 2024**

ISSN: in process

Copyright © Instituto Politécnico Nacional 2024
Formerly ISSNs: 1870-4069, 1665-9899

Instituto Politécnico Nacional (IPN)
Centro de Investigación en Computación (CIC)
Av. Juan de Dios Bátiz s/n esq. M. Othón de Mendizábal
Unidad Profesional “Adolfo López Mateos”, Zácatenco
07738, México D.F., México

<http://www.rcc.cic.ipn.mx>
<http://www.ipn.mx>
<http://www.cic.ipn.mx>

The editors and the publisher of this journal have made their best effort in preparing this special issue, but make no warranty of any kind, expressed or implied, with regard to the information contained in this volume.

All rights reserved. No part of this publication may be reproduced, stored on a retrieval system or transmitted, in any form or by any means, including electronic, mechanical, photocopying, recording, or otherwise, without prior permission of the Instituto Politécnico Nacional, except for personal or classroom use provided that copies bear the full citation notice provided on the first page of each paper.

Indexed in LATINDEX, DBLP and Periodica

Electronic edition

Table of Contents

	Page
Hábitos alimenticios en los alumnos de 18 a 25 años pertenecientes a UPIIG, en la modalidad educativa en línea	5
<i>Yazpik Hernández-Vargas, Génesis Sarahi Portillo-Gómez, Gilda Rosa Bolaños-Evia</i>	
Automatic Processing of Chest X-Rays to Identify Tuberculosis	13
<i>Omar Villalpando-Vargas, Aron Hernández-Trinidad, Blanca Olivia Murillo-Ortiz, Rafael Guzmán-Cabrera, Luis Carlos Padierna-García, Teodoro Córdova-Fraga</i>	
Clasificación e identificación de desgaste en herramientas en procesos de mecanizado a través de redes neuronales.....	19
<i>Mayra Alejandra de los Ángeles Mejía-Moreno, Rafael Guzmán-Cabrera</i>	
Clasificación automática de textos estructurados utilizando inteligencia artificial.....	27
<i>Michelle Alejandra Meléndez-Cardiel, Rafael Guzmán-Cabrera</i>	
Hsi Optical System by Conjugation of the Pupil with the Surface of a Refracting Mirror.....	35
<i>Luis Arturo Tapia-Alarcón, Martín Alberto Vázquez-Castrejon, J. Jesús Escobedo-Altorre, Omar Palillero-Sandoval</i>	
Development and Evaluation of a RapidPlan-Based Semi-Automated Learning System for Prostate Cancer Treatment Planning	41
<i>Sandra Arrieta, Alberto Hardy, Nestor Aragón, Omar Hernández</i>	

Hábitos alimenticios en los alumnos de 18 a 25 años pertenecientes a UPIIG, en la modalidad educativa en línea

Yazpik Hernández-Vargas, Génesis Sarahi Portillo-Gómez,
Gilda Rosa Bolaños-Evia

Instituto Politécnico Nacional,
Unidad Profesional Interdisciplinaria de Ingenierías Campus Guanajuato
Mexico

y hernandezv@ipn.mx

Resumen. Se realizó una encuesta a 100 alumnos de la UPIIG para obtener datos estadísticos que indiquen una variación de sus hábitos alimenticios con respecto al cambio de la modalidad escolarizada presencial a la modalidad en línea. Los resultados obtenidos en la encuesta realizada acerca de cómo evaluarían sus hábitos alimenticios actuales. Se obtuvo que el 42.6% de los encuestados califican sus hábitos como regulares, 40.7% como buenos, 15.7% como malos y tan solo el 0.9% como excelentes. De acuerdo con la investigación, es evidente que existe un cambio en los hábitos alimenticios de los estudiantes de la UPIIG debido a la modalidad en línea, ya que más del 50% de los encuestados dicen haber aumentado de peso.

Palabras clave: Hábitos, alimentación, estudiantes.

Eating Habits in Students from 18 to 25 Years Old Belonging to UPIIG, in the Modality Online Educational

Abstract. Through studies by health institutions, it was possible to show that young university students are indifferent to their eating habits, characterized by omitting the main meals of the day such as breakfast and dinner, not drinking water during the day, insufficient consumption of fruits and vegetables in their diet. A survey was carried out with 100 UPIIG students to obtain statistical data that indicate a variation in their eating habits with respect to the change from the face to face school modality to the online modality. The results obtained in the survey about how they would evaluate their current eating habits, it was obtained that 42.6% of those surveyed rates their habits as regular, 40.7% as good, 15.7% as bad and only 0.9% as excellent. 90.7% of those surveyed answered that there was a change in their diet due to the new modality of online classes. According to the research, it is evident that there is a change in the eating habits of UPIIG students due to the online modality, since more than 50% of the respondents say they have gained weight.

Keywords: Habits, food, students.

1. Introducción

Los hábitos alimenticios son un conjunto de actividades adquiridas por un individuo, es una serie de actos en cuanto a la selección, preparación y consumo de alimentos, se relacionan principalmente con los factores sociales, económicos, culturales y psicológicos de una población o región determinada (Barzola & Bazantes, 2018).

La juventud es una etapa compleja donde se deja de lado a la alimentación, en el que las transformaciones biológicas, psicológicas y sociales provocan un cambio conductual, aunado a esto el reciente cambio de modalidad de clases virtuales, ha revolucionado los hábitos alimenticios de los jóvenes, que si bien es cierto necesitan alimentarse bien para poder fortalecer a su organismo y puedan mantener un buen desempeño académico.

La Organización Mundial de la Salud (O.M.S.), asegura que los jóvenes universitarios dejan de lado su alimentación y llegan a omitir comidas principales del día por diferentes factores y también resalta el poco consumo de frutas y verduras por día (Callisaya & Seleme, 2016, p. P.13). Entonces, los jóvenes que tienen indiferencia en cuanto sus hábitos alimenticios están más propensos a diferentes enfermedades. Repercutiendo directamente en su desempeño académico. Por ello, es fundamental examinar y fortalecer sus conocimientos en cuanto al cuidado de su alimentación.

Para identificar los patrones de los hábitos alimenticios que adoptan los jóvenes universitarios, esta investigación se basa en los estudios realizados por la Organización Mundial de la Salud (O.M.S.), Instituto de Investigación en Salud y Desarrollo (I.N.S.A.D.), Seguridad Alimentaria Nutricional (S.A.N.), Derecho Humano a una Alimentación Adecuada (D.H.A.A.) (Callisaya & Seleme, 2016, p. 14).

Estudios realizados por la Organización Mundial de la Salud (O.M.S.), en los informes que llevan por título los conocimientos actuales sobre nutrición, el perfil participativo de la vulnerabilidad a la inseguridad alimentaria, Ministerio de Salud y Deportes, han comprobado que los patrones de alimentación más cercanos a la tradicional dieta mediterránea, caracterizados por el consumo de dos litros de agua por día, las frutas y verduras, frutos secos, legumbres y pescado, aceite de oliva y un bajo consumo en grasas de origen animal, contribuyen a reducir el riesgo de padecer alguna enfermedad cardiovascular y por lo tanto contribuyen al desempeño académico de los jóvenes universitarios (Callisaya & Seleme, 2016, p. 16).

Actualmente los estudiantes de la Unidad Profesional Interdisciplinaria de Ingeniería Campus Guanajuato se enfrentaron a la modalidad de clases virtuales a causa de SARS-COV 2. Derivado de ello se ha manifestado un descuido en su alimentación a causa de atender las clases en línea. Una etapa crítica en la adquisición de buenos hábitos alimenticios ocurre en la infancia, pero también en la vida universitaria. Ahora con la actual modalidad de clases virtuales, ha provocado un desajuste significativo en los hábitos alimenticios de los estudiantes de la UPIIG.

Los estudiantes presentan períodos de clases de entre 5 a 6 horas continuas, además de las tareas propias de cada materia, las cuales incrementan las horas para dedicar su elaboración, por ejemplo, realizar una tarea de plataforma virtual UPIIG de una materia de matemáticas con 25 ejercicios les toma un tiempo aproximado de 9 horas (tomando en cuenta la elaboración de procedimientos), no obstante proyectos, cursos extracurriculares y actividades cotidianas.

Hábitos alimenticios en los alumnos de 18 a 25 años pertenecientes a UPIIG, en la modalidad ...

¿COMO EVALUARIAS TUS HABITOS ALIMENTICIOS ACTUALES?

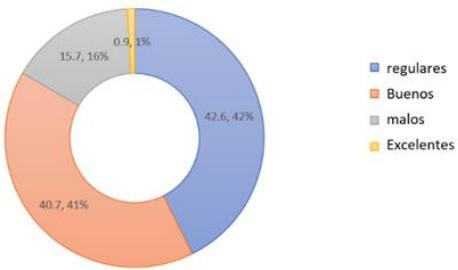


Fig. 1. Hábitos alimenticios actuales.

¿Crees que tu alimentación ha cambiado debido a la nueva modalidad educativa a distancia?

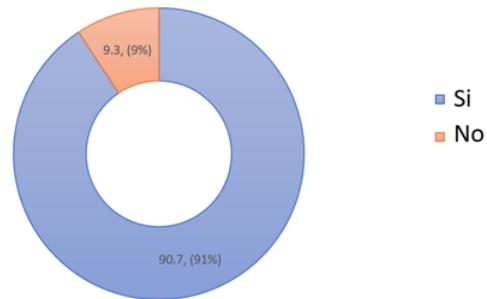


Fig. 2. Alimentación nueva modalidad educativa.

Bajo estas circunstancias, los alumnos pierden el interés de su alimentación, incrementando el consumo de alimentos procesados, poco saludables o retrasan sus horarios de comida, que podrían provocar problemas de salud a corto y largo plazo.

2. Metodología

La presente investigación, busca indagar los hábitos alimenticios que adoptaron ante la modalidad de clases virtuales los jóvenes de la Unidad Profesional de Ingeniería Campus Guanajuato (UPIIG). Para ello, se hará uso de herramientas como la encuesta y entrevista, que permitirán la recolección de datos.

Se realizó una encuesta a 100 alumnos de la UPIIG para obtener datos estadísticos que indiquen una variación de sus hábitos alimenticios con respecto al cambio de la modalidad escolarizada presencial a la modalidad en línea. En el siguiente enlace se puede visualizar la encuesta completa:

<https://forms.gle/xQzTiK6xoiVmEQDM9>

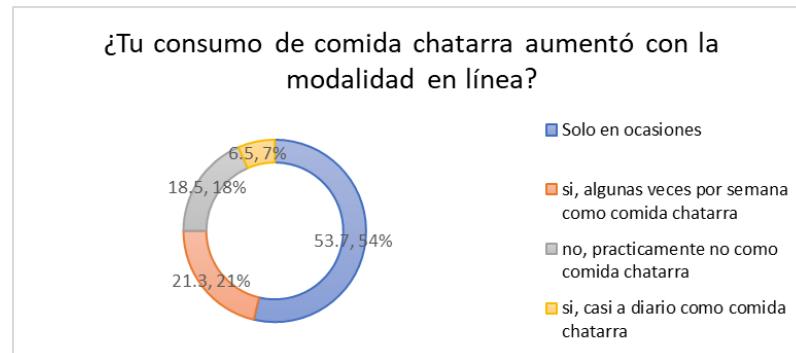


Fig. 3. Consumo comida chatarra.

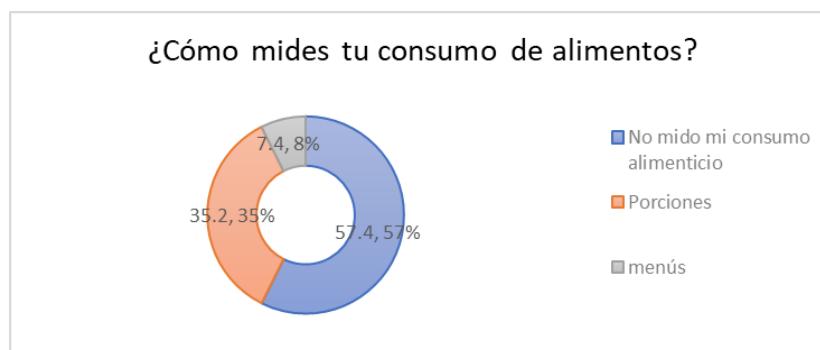


Fig. 4. Medición de consumo alimenticio.

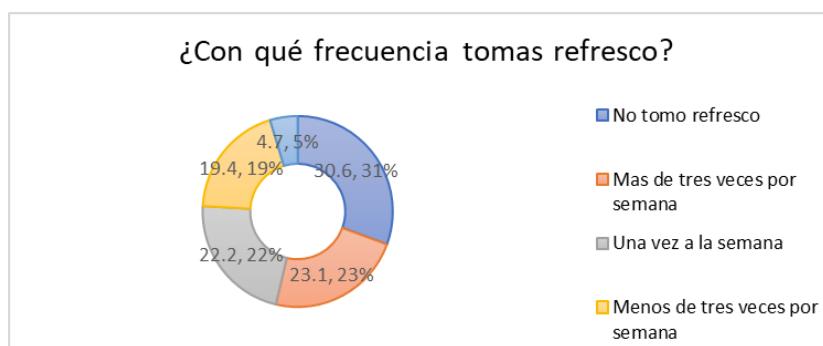


Fig. 5. Consumo de refresco.

Una vez obtenida esta información, podrán ser comparados los resultados entre el grupo de trabajo para llegar a una conclusión y poder dar un punto de vista dirigido a cualquier lector de esta investigación.

Adicionalmente, se realizó una entrevista a una nutrióloga, para averiguar qué aspectos negativos se pueden contraer con malos hábitos alimenticios y cómo se pueden corregir.

Hábitos alimenticios en los alumnos de 18 a 25 años pertenecientes a UPIIG, en la modalidad ...

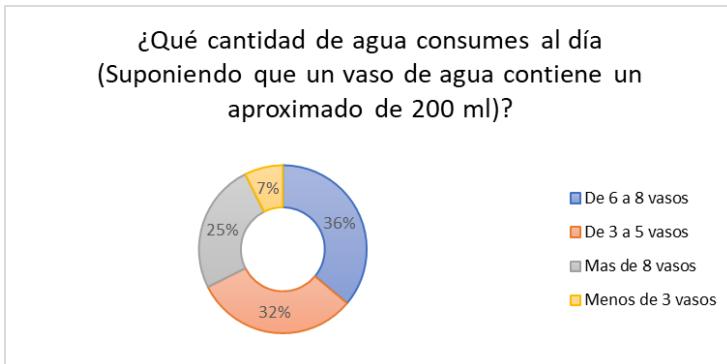


Fig. 6. Consumo de agua.

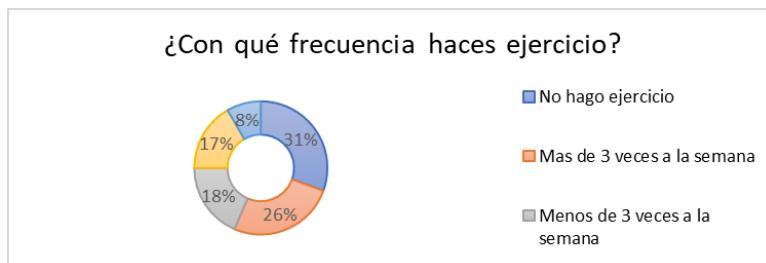


Fig. 7. Frecuencia del ejercicio.



Fig. 8. Peso corporal.

3. Resultados

Se muestran los resultados obtenidos en la encuesta realizada a 100 alumnos pertenecientes de la UPIIG, los cuales se podrán visualizar por medio de gráficos para su comprensión.

Se cuestionó a los alumnos acerca de cómo evaluarían sus hábitos alimenticios actuales, los resultados arrojados se muestran en la Figura 1, donde se puede observar que el 42.6% de los encuestados califican sus hábitos como regulares, 40.7% como buenos, 15.7% como malos y tan solo el 0.9% como excelentes.

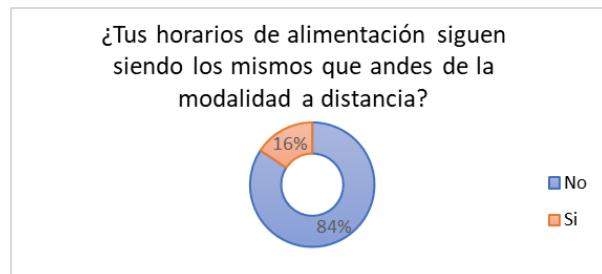


Fig. 9. Horarios de alimentación.



Fig. 10. Cantidad de hora en actividades escolares.

El 90.7% de los encuestados respondió que sí hubo un cambio en su alimentación debido a la nueva modalidad de clases en línea (véase Figura 2), derivada del virus SARS-COV 2, lo cual hace notar que hubo un cambio muy significativo en sus hábitos de alimentación.

En cuanto al consumo de comida chatarra un poco más de la mitad de los encuestados (53.7%) respondió que aumentó su consumo de manera ocasional (Sisu et al., 2020). El 18.5% de los estudiantes respondió que no consumen este tipo de alimentos, en contraste con un 6.5% que admitió consumirlos diariamente, se observa en este sentido un cambio inducido por la modalidad virtual (Sisu et al., 2020).

Se cuestionó a los estudiantes acerca de cómo miden su consumo de alimentos, las opciones eran: porciones, menús, no medir su consumo de alimentos u otro. Más de la mitad de las personas encuestadas respondió no medir su consumo alimenticio, lo cual puede tener como consecuencia, el abuso de algún alimento que con el tiempo puede provocar algún padecimiento derivado del exceso.

Respecto al consumo de refresco, se obtuvieron respuestas variadas, las cuales muestran que los estudiantes no tienen una tendencia muy marcada en cuanto a su consumo. De hecho, el 30.6% de las personas que se encuestaron respondieron que no consumen este tipo de bebidas, 23.1% lo consumen más de tres veces a la semana, 19.4% menos de tres veces a la semana y solo el 6.5% diariamente (véase Fig. 5).

El 25% de los encuestados admitió consumir más de 1.6 litros de agua diariamente, sabiendo que según la secretaría de salud el consumo recomendado es de 2 a 3 litros, aunque las necesidades pueden variar de acuerdo con edad, sexo, dieta y tipo de actividad física (Secretaría de Salud, 2017).

Hábitos alimenticios en los alumnos de 18 a 25 años pertenecientes a UPIIG, en la modalidad ...

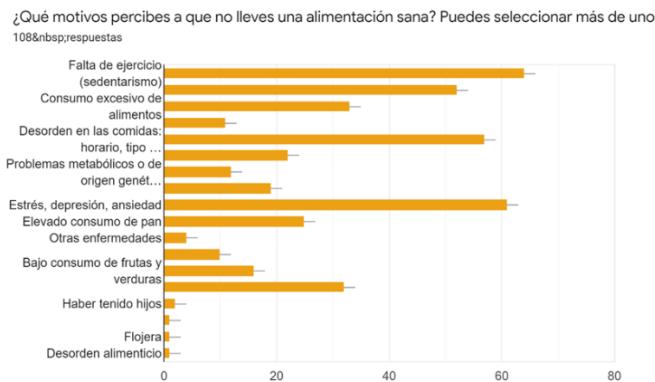


Fig. 11. Motivos de una alimentación poco saludable.

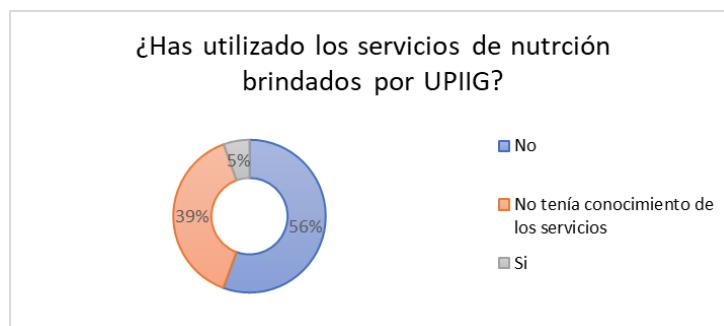


Fig. 12. Gráfica servicios de nutrición.

Otra de las preguntas en cuestión fue la frecuencia con la cual los estudiantes hacen ejercicio, 30.6% contestó que no hace ejercicio y solo el 8.3% lo realiza diariamente, los porcentajes restantes hacen ejercicio de manera menos frecuente, por ejemplo: una vez por semana (16.7%), menos de tres veces a la semana (18.5%) o más de tres veces por semana (25.9%).

El 51.9% de los estudiantes encuestados respondió que debido a la modalidad de clases en línea su peso corporal aumentó. Esto aunado a los datos obtenidos con anterioridad respecto al consumo de agua y la falta de medición en las porciones de alimentos, es una cifra un tanto predecible, pero cabe mencionar que no solo estos aspectos pueden provocar el aumento del peso.

Los horarios de alimentación en los estudiantes debido a la modalidad de clases en línea también cambiaron según los resultados obtenidos en la encuesta. Ya que el 84.13% de los encuestados respondió que efectivamente sus horarios para consumir alimentos no eran los mismos que antes de la modalidad educativa actual (véase Fig. 9).

Se indago sobre la cantidad de horas dedicadas por semana a actividades escolares, los resultados obtenidos se visualizan en la Fig. 10. Se destaca que solo el 13% de los encuestados asignan menos de 10 de horas a la semana y resto entre 20 y 40 horas por semana a las actividades escolares.

Se sabe que hay varios motivos por los cuales una persona puede llevar una alimentación poco saludable. En la encuesta realizada se mencionaron algunos de ellos (véase Fig. 11), para observar cuales son aquellos que más sobresalen entre los estudiantes universitarios pertenecientes a UPIIG. Entre los motivos que obtuvieron un mayor porcentaje fueron: sedentarismo (59.3%), estrés, depresión y ansiedad (56.5%) y desorden en las comidas: horario, tipo de comidas (52.85%).

Finalmente se cuestionó a los estudiantes si habían hecho uso de los servicios de nutrición impartidos en la Unidad Académica. El 55.6% respondió que no tenía conocimiento acerca de este servicio y solo el 5.6% que sí había hecho uso de él.

4. Conclusiones

De acuerdo con la investigación, es evidente que existe un cambio en los hábitos alimenticios de los estudiantes de la UPIIG debido a la modalidad en línea, ya que más del 50% de los encuestados dicen haber aumentado de peso. Respecto a la entrevista realizada a la nutrióloga Karina Portillo la alimentación es uno de los factores que afectan al rendimiento académico, ya que llevar una vida saludable es la clave en la obtención de beneficios a nivel académico, lo cual responde a la hipótesis planteada en donde se concluye que la alimentación sí influye en el rendimiento académico.

Se observa que la falta de tiempo es uno de los principales factores que impiden una alimentación saludable mientras los estudiantes están en etapa de formación profesional, debido a la carga de materias y al tiempo que dedican a ellas. Esta limitación condiciona la calidad de su alimentación.

Cabe destacar que solo el 10% del alumnado tiene conocimiento de los servicios nutricionales brindados por la institución, lo cual abre otra interrogante para este proyecto, ¿Existe una difusión efectiva para dar a conocer este tipo de apoyos escolares a los alumnos de la UPIIG?

Los resultados son concluyentes la modalidad virtual implementada durante la pandemia en estudiantes la UPIIG, incremento el peso corporal de los estudiantes, así como también modifíco horarios de alimentación y sedentarismo, causas que repercuten en la salud física y emocional de los discentes.

Referencias

1. Barzola-Palma, S. E.: Rol del docente frente a los malos hábitos nutricionales del estudiantado y su impacto en la enseñanza. Bachelor's thesis, BABAHOYO: UTB (2018)
2. Callisaya, L. M., Seleme, A. M.: Hábitos alimentarios de riesgo nutricional en estudiantes de primer año de la carrera de ciencias de la educación en la universidad de San Andrés de la Ciudad de la Paz. Universidad Mayor de San Andrés (2016)
3. Secretaría de Salud. La importancia de una buena hidratación. Gobierno de México (2017)
4. Sisu, M. G., Peliti, P., Casana, N. L., Mateos, M. F.: Impacto en los hábitos saludables de estudiantes universitarios de Medicina, durante el Aislamiento Social Preventivo y Obligatorio. Sbarra Científica, vol. 2, no. 1, pp. 1–13 (2020)

Automatic Processing of Chest X-Raysto Identify Tuberculosis

Omar Villalpando-Vargas¹, Aron Hernández-Trinidad¹,
Blanca Olivia Murillo-Ortiz², Rafael Guzmán-Cabrera³,
Luis Carlos Padierna-García¹, Teodoro Córdova-Fraga¹

¹ Universidad de Guanajuato Campus León,
División de Ciencias e Ingenierías,
Mexico

² Unidad de Investigación en Epidemiología, IMSS No.1,
Unidad de Medicina de Alta Especialidad,
Mexico

³ Universidad de Guanajuato Campus Irapuato,
División de Ingenierías,
Mexico

{o.villalpandovargas, aron.hernandez, guzmanc, lc.padierna}@ugto.mx,
bomo907@hotmail.com, theo@fisica.ugto.mx

Abstract. In recent years, Artificial Intelligence has become a helpful tool for medical diagnosis. Through techniques such as deep learning, relevant information on medical images is obtained that helps to characterize and detect pathologies, such as tuberculosis; one of the ten most common deaths in the world. A method of automatic classification for chest radiographs to identify tuberculosis is proposed. The convolutionalbase of a convolutional neural network with 16 hidden layers is used: VGG16, which extracts the most relevant characteristics to enter later a classification system. The proposed model obtained 97% accuracy under the evaluation methods: training/test set and cross validation, the efficiency of the reported classification scenario represent a computer assisted diagnosis for the detection and medical images of tuberculosis. Since the results are competitive with those reported in state of the art, it can be applied to different pathologies of chest X-rays.

Keywords: Tuberculosis, chest X-rays, pathologies of chest, VGG16 architecture.

1 Introduction

According to the World Health Organization (WHO), tuberculosis (TB) is in the ten leading causes of death in the world. This disease is caused by mycobacterium tuberculosis, which usually affects the lungs as well as other parts of the body. TB has a high mortality rate of around 50%, without treatment. Mexico in 2019 had between 23,000 and 37,000 new cases of TB, with a rate of 23 cases per 100,000 inhabitants, primarily young adults. Recently, it continues to represent a significant problem and according to reported figures, an excess in the number of expected cases has occurred in recent years, mainly in young adults of both sexes; the rate is estimated

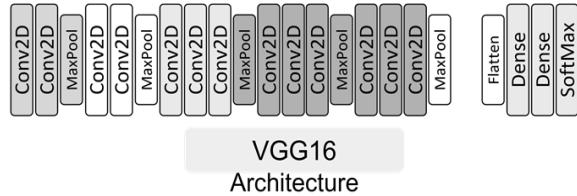


Fig. 1. Convolutional base (before flatten) of the neural network used to obtain the most important characteristics of chest radiographs to identify tuberculosis.

at 51.7 cases per 100, 000 inhabitants. The most used diagnosis to detect tuberculosis is through chest X-rays [1].

Artificial Intelligence (IA) currently encompasses a wide variety of subfields, such as deep learning, which attempts to model high level abstractions in data using computational architectures that support multiple and iterative nonlinear transformations of data expressed in matrix or tensor form. Therefore, automatic learning represents an emerging area in computer assisted diagnosis to detect, through imaging, different pathologies [2].

In the present study, a convolutional neural network (CNN) is implemented, which corresponds to receptive fields in a very similar way to neurons in the primary visual cortex of a biological brain. This type of network is very effective for artificial vision tasks, such as image classification and segmentation, since its application is carried out in two dimensional matrices [3]. The VGG16 is a CNN architecture [4]. Its name comes from the developer team Visual Geometry Group, in Oxford University, and the number of preprocessing layers it contains (16 processing layers) as illustrated in Fig. 1.

The model only requires a specific preprocessing that consists of subtracting from each pixel the average RGB value, calculated in the training set. During model training, the input to the first convolution layer is an RGB image of size 224 x 224. For all convolution layers (Conv2D), the convolution kernel is of size 3x3: the smallest dimension to capture the notions top, bottom, left/right and center. This was a model specificity at the time of publication [5]. Until VGG16, many models were geared towards higher dimensional convolution kernels (size 11 or size 5, for example).

Remember that the objective of these layers is to filter the image, keeping only the discriminating information, such as atypical geometric shapes. These convolution layers are accompanied by Max Pooling layers, each 2x2 in size, to reduce the size of the filters during training. At the output of the convolution and pooling layers, we have 3 layers of fully connected neurons. The first two are composed of 4096 neurons and the last one of 1000 neurons with a softmax activation function to determine the image class [6]. As it can see, the architecture is clear and easy to understand, which is also a strongpoint of this model.

2 Methodology

A data set from the Montgomery County Tuberculosis Screening Program was used. This set contains 138 frontal chest radiographs manually labeled by experts in the field,

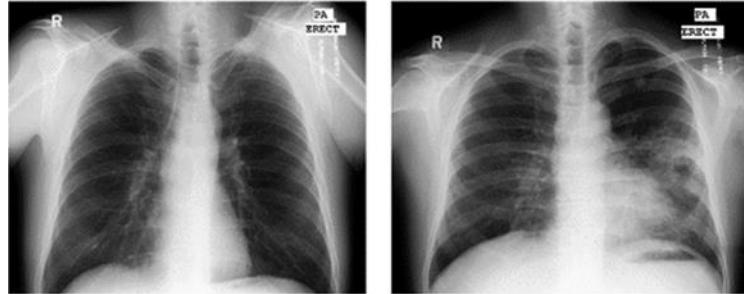


Fig. 2. Sample from the Montgomery dataset reported in the Kaggle repository with 138 chest radiographs divided into (left) normal and (right) tuberculosis.

of which 80 are normal cases and 58 are cases with manifestations of TB. In Fig. 2 is shown the two class types of the data set used in the proposed methodology. Thoracic images require preprocessing before entering the VGG16 architecture, this step is important, since the neural network needs to extract features from the structure images themselves. Preprocessing consists of resizing all X-ray images to 224×224 pixels.

The VGG16 architecture was used as a feature extractor through its convolutional base, to obtain a feature vector. Subsequently, the vector entered two classification scenarios: cross validation (CV) with 10 and 20 folds for the original training set, respectively; and training/test set providing 80% of the data set for training and 20% for testing the scenario.

For both classification scenarios, three classifiers were used: Support Vector Machine (SVM), Naïve Bayes (NB), and Centroid Based Classifier (CBC), since these classifiers have reported strong and competitive values in the literature, in other words, the three are widely used in state of the art. To quantify the behavior of the proposed methodology, the accuracy and precision evaluation metrics were used, based on the confusion matrix, which permits identifying true or false predictions. Fig. 3 illustrates the proposed model.

The input to cov1 layer is of fixed size 224×224 RGB image. The image is passed through a stack of convolutional (conv.) layers, where the filters were used with a very small receptive field: 3×3 (which is the smallest size to capture the notion of left/right, up/down, center). In one of the configurations, it also utilizes 1×1 convolution filter, which can be seen as a linear transformation of the input channels (followed by non-linearity).

The convolution stride is fixed to 1 pixel; the spatial padding of conv. layer input is such that the spatial resolution is preserved after convolution, i.e. the padding is 1-pixel for 3×3 conv. layers.

Spatial pooling is carried out by five max pooling layers, which follow some of the conv. layers (not all the conv. layers are followed by max pooling). Max-pooling is performed over a 2×2 -pixel window, with stride 2 [7].

Three Fully Connected (FC) layers follow a stack of convolutional layers (which has a different depth in different architectures): the first two have 4096 channels each, the third performs 1000-way ILSVRC (ImageNet Large-Scale Visual Recognition

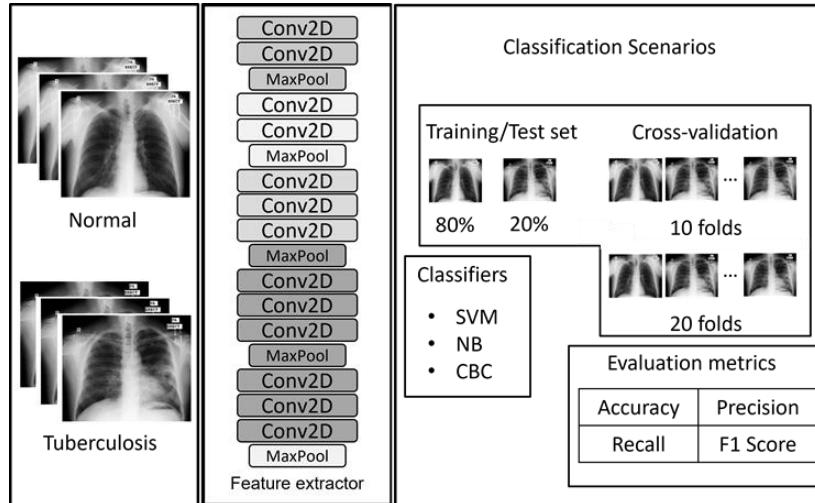


Fig. 3. Automatic processing model of chest radiographs to identify tuberculosis.

Table 1. Training/Test set classification scenario results.

Train/Test set			
Evaluation metrics	SVM	NB	CBC
Accuracy	0.96	0.86	0.86
Precision	0.97	0.87	0.87
Recall	0.96	0.84	0.84
F1 Score	0.96	0.85	0.85

Table 2. Results of the cross-validation classification scenario.

Train/Test set				
Folds	Evaluation metrics	SVM	NB	CBC
10	Accuracy	0.82	0.75	0.72
	Precision	0.86	0.78	0.74
	Recall	0.82	0.74	0.72
	F1 Score	0.81	0.73	0.71
20	Accuracy	0.86	0.76	0.74
	Precision	0.89	0.77	0.76
	Recall	0.85	0.75	0.73
	F1 Score	0.85	0.73	0.72

Challenge) classification and thus contains 1000 channels (one for each class). The final layer is the soft max layer. The configuration of the fully connected layers is the same in all networks.

All hidden layers are equipped with the rectification (ReLU) non-linearity. It is also noted that none of the networks (except for one) contain Local Response Normalisation (LRN), such normalization does not improve the performance on the ILSVRC dataset, but leads to increased memory consumption and computation time. The VGG is a popular computer vision algorithm that is often used using transfer learning to avoid having to retrain it and solve similar problems that the VGG has already been trained on.

There are many other algorithms of the same type as VGG like ResNet or Xception available in the Keras library [8].

3 Results

In the training/test set scenario, the best results are obtained with the SVM classifier, reaching 97% accuracy. The results are shown in Table 1. The columns show the classifiers with the respective evaluation metrics. Table 2 shows the results for the CV method, comparing the fold increase, obtaining the best results in the SVM classifier using 20 folds, with 89% accuracy.

4 Conclusion

The proposed model of automatic classification of chest radiographs to detect tuberculosis obtained 97% accuracy. The value obtained is due to the improvement of the characteristics of chest radiographs, using a convolutional neural network (CNN) from the Visual Geometry Group (VGG16). The reported model is competitive with the state of the art, as well as a support tool in the medical diagnosis of tuberculosis.

Acknowledgment. This work was partially supported by University of Guanajuato under grant no.DAIP2022/59023.

References

1. Meraj, S. S., Yaakob, R., Azman, A., Rum, S. N. M., Nazri, A. S. A.: Artificial intelligence in diagnosing tuberculosis: A review. *International Journal on Advanced Science, Engineering and Information Technology*, vol.9, pp. 81–91 (2019)
2. Kant, S., Srivastava, M. M.: Towards automated tuberculosis detection using deep learning. In: 2018 IEEE Symposium Series on Computational Intelligence (SSCI), IEEE, pp. 1250–1253 (2018)
3. Rahman, T., Khandakar, A., Kadir, M. A., Islam, K. R., Islam, K. F., Mazhar, R., Hamid, T., Islam, M. T., Kashem, S., Mahbub, Z. B., Ayari, M. A., Chowdhury, M. E. H.: Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization. *IEEE Access*, vol. 8, pp. 191586–191601 (2020) doi: 10.1109/ACCESS.2020.3031384
4. Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition. pp. 1409–1556 (2015) doi: 10.48550/arXiv.1409.1556
5. Chowdary, G. J., Suganya, G., Premalatha, M., Karunamurthy, K.: Class dependency-based learning using BI-LSTM coupled with the transfer learning of VGG16 for the diagnosis of tuberculosis from chest x-rays. (2021) doi: 10.48550/ arXiv.2108.04329
6. Meraj, S. S., Yaakob, R., Azman, A., Rum, S., Shahrel, A., Nazri, A., Zakaria, N. F.: Detection of pulmonary tuberculosis manifestation in chest x-rays using different convolutional neural network (CNN) models. *International Journal Engineering and Advanced Technology (IJEAT)*, vol.9, no. 1, pp. 2270–2275 (2019) doi: 10.35940/ijeat.A2632.109119
7. Qassim, H., Verma, A., Feinzimer, D.: Compressed residual-VGG16 CNN model for big data places image recognition. In: 2018 IEEE 8th annual computing and communication workshop and conference (CCWC), IEEE, pp. 169–175 (2018)

Omar Villalpando-Vargas, Aron Hernández-Trinidad, Blanca Olivia Murillo-Ortiz, et al.

8. Gulli, A., Pal, S.: Deep learning with Keras. Packt Publishing Ltd (2017)

Clasificación e identificación de desgaste en herramientas en procesos de mecanizado a través de redes neuronales

Mayra Alejandra de los Ángeles Mejía-Moreno,
Rafael Guzmán-Cabrera

Universidad de Guanajuato,
Departamento de Estudios Multidisciplinarios (Yuriria),
División de Ingenierías,
CampusIrapuato-Salamanca,
México

madla.mejiamoreno@ugto.mx

Resumen: Las operaciones de mecanizado desempeñan un papel importante en la industria metalmecánica por eso es de gran interés poder identificar de manera temprana el desgaste de las herramientas de corte para optimizar los procesos. No identificar a tiempo este estado puede tener un gran impacto en la calidad del mecanizado, la eficiencia de la producción y afecta de manera directa los costos en la industria del corte de metales, por lo que es importante mantener bajo control el nivel del desgaste durante las operaciones de mecanizado. En este trabajo se presentan resultados utilizando distintos métodos de aprendizaje automático para la clasificación automática de imágenes con la finalidad de identificar los defectos presentados en las mismas. El preprocesamiento, la extracción y la visión artificial para extraer características relevantes de las imágenes son el primer paso para obtener valores de clasificación adecuados de un conjunto de imágenes con 2 tipos de desgastes definidos como los de más incidencia en los insertos de corte. El objetivo principal de este trabajo es evaluar estrategias para detectar de manera temprana y entrenar redes neuronales artificiales para el reconocimiento automático del desgaste utilizando imágenes de las herramientas capturadas por medio de visión por computadora. Para la evaluación del método se utilizaron tres métodos de aprendizaje automático: Redes Neuronales, Máquinas de vectores de soporte y vecinos más cercanos. Se implementaron dos escenarios de clasificación: validación cruzada y formando conjuntos de entrenamiento y prueba. Los resultados obtenidos permiten ver la viabilidad del método propuesto.

Palabras claves: Clasificación de imágenes, detección del desgaste de herramientas de corte, aprendizaje automático, visión por computadora.

Classification and Identification of Tool Wear in Machining Processes through Neural Networks

Abstract: Machining operations play an important role in the metalworking industry, which is why it is of great interest to be able to identify the wear of cutting tools early

to optimize processes. Failure to identify this condition in time can have a great impact on the quality of machining, production efficiency and directly affects costs in the metal cutting industry, so it is important to keep the level of wear under control during machining operations. In this work, results are presented using different machine learning methods for the automatic classification of images in order to identify the defects presented in them. Preprocessing, extraction and computer vision to extract relevant features from the images are the first step to obtain adequate classification values from a set of images with 2 types of wear defined as those with the most incidence in the cutting inserts. The main objective of this work is to evaluate strategies to early detect and train artificial neural networks for automatic wear recognition using tool images captured through computer vision. For the evaluation of the method, three machine learning methods were used: Neural Networks, Support Vector Machines and Nearest Neighbors. Two classification scenarios were implemented: cross-validation and forming training and test sets. The results obtained allow us to see the viability of the proposed method.

Keywords: Image classification, cutting tool wear detection, machine learning, computer vision.

1. Introducción

Las herramientas de inserto indexado se han convertido en referencia mundial en procesos de corte mecánico ya que proporcionan una mayor productividad y mecanizado de alta velocidad ideal para trabajos de acabado en acero o hierro fundido. En estas herramientas se han identificado dos tipos de desgaste comunes, cráter y flanco. En la Figura 1 y Figura 2 podemos distinguir los dos tipos de desgaste.

El reconocimiento de las condiciones generales de una herramienta de corte tiene un papel importante en la optimización de los procesos de mecanizado, ya que la predicción precisa del momento exacto para el cambio de herramienta da como resultado en muchos casos una economía efectiva: se puede lograr una mayor vida útil de la herramienta de corte, se pueden controlar las tolerancias y evitar el rechazo de piezas por deterioro de las condiciones de la herramienta [1].

El procesamiento digital de imágenes (PDI) es una herramienta ampliamente utilizada en la automatización de procesos industriales, debido a que presenta confiabilidad, eficacia y rapidez en el procesamiento [2]. El PDI es el conjunto de técnicas que se aplica a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información, usando como herramienta principal una computadora. Hoy en día, el PDI es un área de investigación muy específica en computación [3].

La clasificación de imágenes se refiere a la tarea de categorizar o etiquetar una imagen en función de las características de su contenido. Hay dos tipos de clasificación: supervisada y no supervisada. La clasificación supervisada parte de un conjunto conocido de clases, las cuales se definen en base al conocimiento previo del conjunto de variables.

En cambio, en la clasificación no supervisada, las clases no se establecen a priori; sólo se establece el número esperado de clases, y la definición de las clases se realiza automáticamente mediante procedimientos estadísticos [4]. Una de las técnicas más usadas para el aprendizaje automático son las redes neuronales artificiales por su potencial para reconocer patrones de información, las RNA han sido desde hace décadas herramientas para resolver problemas en cualquiera de los niveles del procesamiento de imágenes.

Esto debido a que las imágenes digitales contienen mucha información difícil de interpretar por una máquina [5]. En las operaciones de fresado, la calidad de la pieza mecanizada depende en gran medida del estado del inserto de corte. Factores como el desgaste, la corrosión o la fatiga pueden afectar el desgaste de la herramienta. Por lo tanto, el monitoreo del desgaste de la herramienta en el proceso de mecanizado ha encontrado su importancia para predecir la vida útil de la herramienta, reducir el tiempo de inactividad del equipo y optimizar los parámetros de mecanizado [6].

El propósito de este artículo es aplicar estrategias para detectar de manera temprana el desgaste de las herramientas por medio de métodos de clasificación y entrenar redes neuronales artificiales para el reconocimiento automático, utilizando imágenes de las herramientas capturadas mediante visión por computadora.

2. Metodología propuesta

Para este trabajo se quiso lograr la clasificación de un conjunto de imágenes captadas por medio de visión por computadora, estas imágenes fueron modificadas, realizando una rotación a 15° grados en sentido de las manecillas del reloj, después de tener las imágenes listas se procede a dividir en subconjuntos. El primer subconjunto cuenta 216 imágenes bajo la etiqueta de Desgaste tipo cráter, El segundo subconjunto cuenta con 216 imágenes bajo la etiqueta de Desgaste tipo flanco y el último grupo cuenta con 72 imágenes etiquetadas como “Sin desgaste”.

Estas imágenes fueron tomadas para identificar el desgaste en herramientas de corte de procesos de mecanizado conocidas como Insertos indexados. El tema que analizamos para esta investigación nos resulta muy interesante porque a través de la detección temprana del desgaste podemos minimizar los costos y el tiempo, así como podemos maximizar la producción de productos con calidad garantizada.

La metodología que se manejó para la elaboración del presente trabajo de investigación se muestra en la figura 1, en donde se ilustra de manera general los pasos que se llevaron a cabo para la elaboración de nuestra investigación. En esta sección se presenta una breve descripción de los clasificadores empleados en los experimentos para observar cual arroja mejores resultados de precisión: Clasificador de redes neuronales (NN), máquina de vectores de soporte (SVM) y K-vecinos más cercanos (K-NN). Las redes neuronales (NN) son redes que utilizan aprendizaje supervisado.

Las redes neuronales son una representación simplificada en forma de gráfico de una malla de neuronas en el cerebro humano. Los nodos son las unidades de procesamiento, y los vínculos representan las conexiones sinápticas. Para simular la fuerza de las conexiones sinápticas, un peso es asociado con cada conexión entre los nodos de la red neuronal. A cada instante, el estado de un nodo es definido por su nivel de activación. Dependiendo de ese nivel de activación el nodo envía una señal al nodo vecino; la fuerza de esa señal dependerá del peso asociado con esa conexión.

Si los valores de los pesos de una red neuronal convergen con los datos del entrenamiento se dice que el problema puede ser representado por una red neuronal [7]. Support Vector Machines (SVM). El clasificador SVM es un algoritmo de aprendizaje supervisado basado en kernel que clasifica los datos en dos o más clases. SVM está especialmente diseñado para la clasificación binaria. Durante la fase de capacitación, SVM construye un modelo, mapea el límite de decisión para cada clase y especifica el hiperplano que separa las

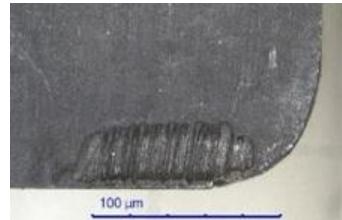


Fig. 1. Desgaste de Cráter.

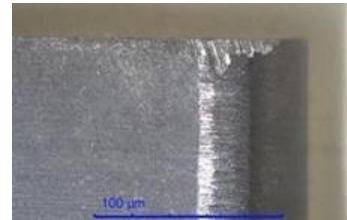


Fig. 2. Desgaste de Flanco.

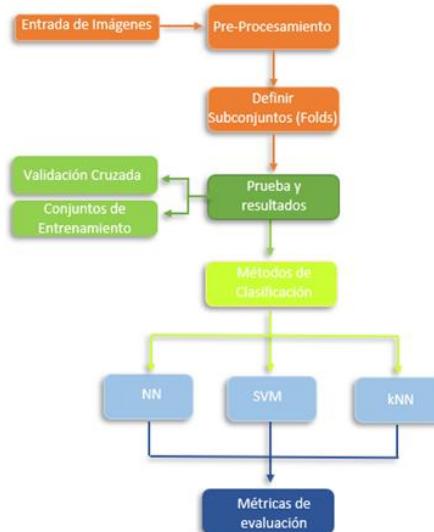


Fig. 3. Metodología propuesta.

diferentes clases. Aumenta la distancia entre las clases, incrementando el margen del hiperplano con la finalidad de ayudar a la precisión de la clasificación. SVM se puede utilizar para realizar de manera efectiva la clasificación no lineal [8].

K-NN su proceso de clasificación se obtiene por la asociación de muestras no etiquetadas a la clase mayoritaria entre las clases de las más cercanas k patrones de entrenamiento en el espacio de características. Por lo general, como una forma de evitar empates en problemas de clasificación binaria, k valor se establece en un entero impar, pero todavía puede haber empates cuando k es un entero impar cuando se trata de problemas de clasificación multiclas. Los parámetros principales para K-NN son el número k de patrones de entrenamiento a considerar para clasificar la nueva muestra y la métrica de distancia [9]. Como métricas de evaluación se utilizaron:

Área bajo la curva (AUC por sus siglas en inglés) es la métrica que mide la precisión de un modelo donde entre más cercano se encuentre a uno se considera que el modelo es más preciso [10]:

$$AUC = \int_0^1 f(x)dx$$

Tabla 1. Resultados métricas de evaluación con Validación cruzada.

Model	AUC	Precisión	Recall
kNN	0.999	0.981	0.980
SVM	1.000	0.994	0.994
NN	1.000	0.996	0.996

Tabla 2. Resultados métricas de evaluación entrenamiento 90%.

Model	AUC	Precisión	Recall
kNN	0.999	0.983	0.982
SVM	1.000	0.992	0.992
NN	1.000	0.994	0.994

Tabla 3. Resultados métricas de evaluación con Validación cruzada.

Model	AUC	Precisión	Recall
kNN	0.999	0.982	0.982
SVM	1.000	0.994	0.994
NN	1.000	0.998	0.998

Tabla 4. Resultados métricos de evaluación entrenamiento 90%.

Model	AUC	Precisión	Recall
kNN	0.999	0.987	0.986
SVM	1.000	0.992	0.992
NN	1.000	0.990	0.990

Precisión: Mide el rendimiento relacionado con las tasas de verdaderos positivos y negativos [11]:

$$Precisión = \frac{TP}{TP + FN}.$$

Recall o sensibilidad es una medida que permite conocer la proporción de casos positivos que fueron correctamente clasificados. En un modelo perfecto el recall es igual a 1 para cada clase [12]:

$$Recall = \frac{tp}{tp + fn}.$$

Se realizaron dos estudios experimentales, uno con el conjunto de imágenes sin pre procesar y el otro con las imágenes pre procesadas en donde se aplicó en Matlab un filtro de escala de grises, luego se realiza la binarización, se segmentó el desgaste y se extrajeron los bordes de las imágenes. Estos estudios se realizaron de esta manera porque actualmente no se cuenta con una base de datos extensa y lo que se quiso lograr es entrenar los clasificadores para que más adelante tenga un mayor impacto de la técnica de procesamiento a la hora de clasificar.

3. Resultados

A continuación, se muestran los resultados obtenidos en los experimentos realizados en un lenguaje de programación de Python. En la Tabla I. se muestran los resultados con las métricas de evaluación con Validación cruzada y en la Tabla II. Se muestra los resultados con las métricas de evaluación con un entrenamiento de 90% con las imágenes sin preprocesar. En las tablas III y IV se muestra los resultados de Validación cruzada y Conjuntos de entrenamiento para imágenes a las que se le realizaron el procesamiento.

La aplicación de la metodología sobre los experimentos nos arroja como resultado un valor de precisión del 100% utilizando redes neuronales en ambos escenarios, a pesar de que no se contaba con una base de datos amplia los clasificadores que mostraron mejor desempeño fueron Redes Neuronales y SVM, el clasificador que mostró menor desempeño en este caso fue el de Vecinos cercanos para ambos experimentos y en los diferentes escenarios de clasificación, aunque la precisión ya era alta en el primer experimento el lograr un incremento en los clasificadores que se encuentran marcados en color naranja y verde, esto es de gran ayuda pensando en cuando se cuente con conjuntos de imágenes más grandes.

Las métricas de evaluación con el mejor rendimiento que se presentaron en ambos casos fue conjuntos de entrenamiento y prueba es por eso por lo que este clasificador se convierte en el óptimo para la realización de experimentos de clasificación de desgaste.

4. Conclusión

En el presente trabajo de investigación se realizaron los experimentos y se presentan los resultados de clasificación automática de las herramientas de inserto indexado con los dos tipos de desgaste y las herramientas sin desgaste. Para hacer la clasificación se implementaron dos escenarios de clasificación: validación cruzada y conjuntos de entrenamiento y prueba, con dos bases de datos que constaban de imágenes sin realizar con extracción de bordes e imágenes con procesos de binarización, segmentación y extracción de bordes. Lo que quería lograr con esto era definir el impacto de la metodología aplicada en ambos escenarios con diferentes conjuntos de imágenes.

Referencias

1. Byrne, G., Dornfeld, D., Inasaki, I., Ketteler, G., König, W., Teti, R.: Tool condition monitoring (TCM)—the status of research and industrial application. In: 8th CIRP Conference on Intelligent Computation in Manufacturing Engineering, Procedia CIRP 12, pp. 252 – 257 (1995)
2. Cáceres-Flórez, C. A., Ramos-Sandoval, O. L., Amaya Hurtado, D.: Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de Begonia semperflorens (flor de azúcar). Acta Agronómica, vol. 64, no. 3, pp. 273–279 (2015) doi: 10.1544/acag.v64n3.42657
3. Morales-Castro, W., Guzmán-Cabrera, R.: Tuberculosis: Diagnóstico por procesamiento de imágenes. Computación y Sistemas, vol. 24, no. 2, pp. 875–882 (2020) doi: 10.13053/cys-24-2-3284

4. Pérez-Careta, E., Guzmán-Sepúlveda, J. R., Lozano-García, J. M., Torres-Cisneros, M., Guzman-Cabrera, R.: Classification of medical images using machine learning. DYNA, vol. 97, no. 1, pp. 35–38 (2022) doi: 10.6036/10117
5. Ramírez, Q. J., Chacón, M., Mario, I.: Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década. RIEE&C, Revista de ingeniería eléctrica, electrónica y computación, vol. 9, no. 1, pp. 7–16 (2011)
6. Wu, X., Liu, Y., Zhou, X., Mou, A.: Automatic identification of tool wear based on convolutional neural network in planning process. Sensors, vol. 19, no. 18, p. 3817 (2019)
7. Godoy-Viera, Á.: Técnicas de aprendizaje de máquina utilizadas para la minería de texto. Investigación Bibliotecológica: archivonomía, bibliotecología e información, vol. 31, no. 71, pp. 103–126 (2017) doi:10.22201/iibi.0187358xp.2017.71.57812
8. Blanco-Murillo, D. M., García-Domínguez, A., Galván-Tejada, C. E., Celaya-Padilla, J. M.: Comparación del nivel de precisión de los clasificadores support vector machines, k nearest neighbors, random forests, extra trees y gradient boosting en el reconocimiento de actividades infantiles utilizando sonido ambiental. Research in Computing Science, vol. 147, no. 5, pp. 281–290 (2018)
9. Pacifico, L. D., Macario, V., Oliveira, J. F.: Plant classification using artificial neural networks. In: 2018 International Joint Conference on Neural Networks (IJCNN), IEEE, pp. 1–6 (2018) doi: 10.1109/IJCNN.2018.8489701
10. Espinosa-Zúñiga, J. J.: Aplicación de algoritmos random forest y XGBoost en una base de solicitudes de tarjetas de crédito. Ingeniería, investigación y tecnología, vol. 21, no. 3 (2020) doi: 10.22201/fi.25940732e.2020.21.3.022
11. Bayas, B. O., Alvarado, P. R., Toapanta, J. M., Zamora, L. S.: Análisis comparativo de modelos de aprendizaje automático para la detección de mensajes considerados como grooming online. Centro Sur, vol. 4, no. 3 (2021)
12. Borja-Robalino, R., Monleón-Getino, A., Rodellar, J.: Estandarización de métricas de rendimiento para clasificadores machine y deep learning. Revista Ibérica De Sistemas y Tecnologías De Información, 184-196 (2020)

Clasificación automática de textos estructurados utilizando inteligencia artificial

Michelle Alejandra Meléndez-Cardiel, Rafael Guzmán-Cabrera

Universidad de Guanajuato,
México

{ma.melendezcardiel, guzmanc}@ugto.mx

Resumen—Una de las tareas más comunes del Data Mining es la clasificación de textos de acuerdo con sus características, para ello es necesario el uso de un corpus con el cual se pueda trabajar para el diseño de un modelo de clasificación dependiendo de laspalabras que contenga cada clase. Con ese fin, se necesita saber discriminar qué etiquetas o cualidades nos serán de utilidad para dicha categorización. Para este trabajo se presenta un análisis con 3 diferentes clasificadores más usados: Support Vector Machine (SVM), Naive Bayes y Regresión Logística. Los experimentos se prueban haciendo uso de 6 carpetas de las 20 que contiene The 20 Newsgroups como corpus, con su tema dirigido a la política y religión; con un 10 por ciento de pruebas. Haciendo uso de Area bajo la curva, Precisión, Recall y Macro-F1 en este trabajo, ya que esas métricas de evaluación son mejores para demostrar el rendimiento del modelo.

Palabras clave: clasificación de textos, inteligencia artificial, minería de datos, decisión.

Automatic Classification of Structured Texts Using Artificial Intelligence

Abstract. One of the most common tasks of Data Mining is the classification of texts according to their characteristics, for this it is necessary to use a corpus with which one can work to design a classification model depending on the words that are used. contain each class. To this end, it is necessary to know how to discriminate which labels or qualities will be useful for said categorization. For this work, an analysis is presented with 3 different most used classifiers: Support Vector Machine (SVM), Naive Bayes and Logistic Regression. The experiments are tested using 6 folders of the 20 that the 20 Newsgroups contains as corpus, with its topic directed to politics and religion; with 10 percent testing. Making use of Area under the curve, Precision, Recall and Macro-F1 in this work, since those evaluation metrics are better to demonstrate the performance of the model.

Keywords: Text classification, artificial intelligence, data mining, decision.

1. Introducción

Las técnicas de inteligencia artificial están destinadas a ayudar a tomar decisiones en escenarios donde la cantidad de información complica el análisis desarrollado por los expertos. El análisis del comportamiento de los consumidores es un problema fundamental para la formulación de estrategias de marketing, ventas, atención al cliente, fidelización, segmentación, cross-selling, optimización de la cadena de suministro, detección y prevención de fraudes y Detección de Anomalías (DA), entre otras [1].

La minería de datos se define como la práctica de examinar una gran base de datos preexistente para generar nueva información. Una tecnología robusta tiene un gran potencial para ayudar a las organizaciones a concentrarse en la información más importante en los almacenes de datos almacenados.

Las herramientas y técnicas de minería de datos predecirán las tendencias futuras al hacer que el negocio sea más proactivo y mejores decisiones basadas en el conocimiento. Las técnicas de minería de datos podrían responder preguntas relacionadas con el negocio que tradicionalmente requerían demasiado tiempo para resolver [2].

La clasificación de texto permite el agrupamiento de documentos semánticamente significativos, ayudando tanto a los usuarios como a las herramientas de recuperación de información, a localizarlos con mayor precisión. En esta sección se compara el rendimiento en términos de precisión de la clasificación [3].

2. Antecedentes

The 20 Newsgroups Dataset se divide en 20 carpetas, cada una con mil archivos aproximadamente, sobre 20 temas. Consta de 20000 mensajes tomados de 20 grupos de noticias. Los mensajes son proporcionados por la Escuela de Informática de la Universidad Carnegie Mellon, que se remonta a 1999.

Los 20000 mensajes representan 1000 artículos de uso neto con aproximadamente el 4% de los artículos publicados de forma cruzada, son publicaciones típicas, por lo que tienen encabezados con líneas de asunto, firma archivos y partes citadas de otros artículos, también cada grupo de noticias se almacena en un subdirectorio, con cada artículo almacenado como un archivo separado.

Este conjunto de datos viene organizado por fecha, y también viene con algo de ruido (como los encabezados "De", "Asunto" en cada publicación como se mencionó anteriormente y también algunos errores tipográficos en el conjunto de datos); algunos de los temas están muy relacionados entre sí, como Hardware MAC y Hardware PC, mientras que otros temas son muy diferentes, como temas cristianos y motocicletas [4].

Este corpus ha sido muy utilizado para diversos trabajos anteriormente, algunos usan todas las carpetas con los mil archivos de cada una, a diferencia de otros únicamente utilizan 6 carpetas, con 2 temas diferentes relacionados y solo 100 archivos de cada carpeta. Para identificar de mejor manera cada trabajo, se presenta a continuación en la Tabla 1 la comparación de cada trabajo.

Tabla 1. Comparativa de resultados obtenidos en algunos trabajos recabados.

	X2	MI	TF	Precisión	Recall	F1	
	93.16%	93.29%	93.36%	-	-	-	[5]
MNB	-	-	-	86%	-	-	[6]
	-	-	-	72%	70%	70%	[7]
	79.15%	79.07%	-	-	-	79.29%	[6]
SVM	93.16%	93.29%	93.36%	-	-	-	[7]
				71%	67%	67%	[7]

2.1 Técnicas de clasificación

Naïve Bayes es un método de clasificación supervisado y generativo que se basa en el teorema de Bayes y en la premisa de independencia de los atributos para obtener la probabilidad de que un documento pertenezca a una determinada clase como se indica en la ecuación que sigue:

$$P(C_i|D) \propto P(C_i) \prod_{k=1}^n P(f_k|C_i), \quad (1)$$

donde f_k son los atributos del documento, C_i es la clase y $P(f_k|C_i)$ es la probabilidad de ocurrencia del atributo en la clase dada. La clase seleccionada por el clasificador será la que maximice la probabilidad anterior. Las implementaciones del algoritmo de Naïve Bayes difieren principalmente en la aproximación de $P(f_k|C_i)$ y las técnicas de smoothing utilizadas para el tratamiento de probabilidades bajas o nulas [8].

Support Vector Machines es un método supervisado de clasificación binaria en el cual el entrenamiento consiste en encontrar un hiperplano que separe los vectores de atributos que representan los documentos del conjunto de datos en dos grupos, siendo esta separación la más grande posible. Aquellos vectores que definen los márgenes de la máxima separación entre las clases se conocen como support vectors.

Para la predicción de la clase utilizando este modelo se define la ecuación que sigue:

$$f(x) = \text{sign} \left(\sum_i \alpha_i x_i \cdot x + b \right). \quad (2)$$

Siendo, x el vector de atributos del documento a clasificar, α_i cada uno de los pesos que ponderan los vectores de atributos identificados como support features, x_i cada uno de los support features y b el término independiente. Un valor de -1 indicará que el documento pertenece a una clase y un valor de $+1$ a la otra, lo que representa de qué lado del hiperplano se encuentra x [8].

La **Regresión Logística** (también conocido como clasificador de máxima entropía), es un modelo matemático utilizado para predecir el resultado de una variable categórica, por lo general dicotómica, en función de las variables independientes o predictoras. La predicción que se obtiene es la probabilidad de pertenecer a cada clase. Una de las ventajas fundamentales de la regresión logística sobre otras técnicas, es que

el resultado del modelo entrenado se puede interpretar fácilmente. Esto se debe a que el coeficiente obtenido para cada variable dependiente, indica de qué manera influye en el modelo dicha variable. Otras ventajas son su simplicidad y eficacia [9].

2.2 Métricas de evaluación

The components update was according to functionality and ease of configuration, they are listed below, see figure 1.

Dos de las medidas para medir el rendimiento son la precisión y el recall. La **precisión** de un clasificador se define como la fracción de etiquetas correctamente asignadas entre todas las etiquetas asignadas por clasificador:

$$\text{Precisión} = \frac{tp}{tp+fp}.$$

El **recall** de un clasificador es la fracción de etiquetas correctamente clasificadas entre todas las etiquetas realmente positivas:

$$\text{Recall} = \frac{tp}{tp+fn},$$

t_p indica el número de instancias positivas clasificados correctamente,

f_p las instancias incorrectamente asignadas o falsos positivos,

f_n las instancias no asignadas o falsos negativos [10].

Área bajo la curva (AUC por sus siglas en inglés) se calcula usando el área bajo la curva ROC y cuanto mayor es el área más precisa es formalmente el predictor, la fórmula para calcular el AUC es representada por:

$$AUC = \int_0^1 f(x)dx,$$

donde $f(x)$ representa la función de la curva característica de funcionamiento del receptor (ROC por sus siglas en inglés), sin embargo, desde $f(x)$ tiende a no tener una forma de integración como una parábola; varios autores sugieren utilizar métodos de aproximación para calcular las AUC.

F1 es una medida de precisión en una prueba que se calcula a partir de la precisión y el recall de la prueba que se está llevando a cabo, en pocas palabras F1 es la media armónica de la precisión y el recall, que se muestra a continuación: [11]:

$$F1 = \frac{tp}{\frac{tp+fp+fn}{2}}.$$

3. Metodología

Para realizar este trabajo se desarrolló la clasificación de documentos pertenecientes a The 20 Newsgroups Dataset, los cuales tienen 20 temas distintos de noticias, un tópico por carpeta, desde deportes y motocicletas, hasta política y religión. Debido a que 3 carpetas son pertenecientes al tema de política: “talk.politics.guns”, “talk.politics.misc” y “talk.politics.mideast” y 3 carpetas corresponden a religión: “alt.atheism”,

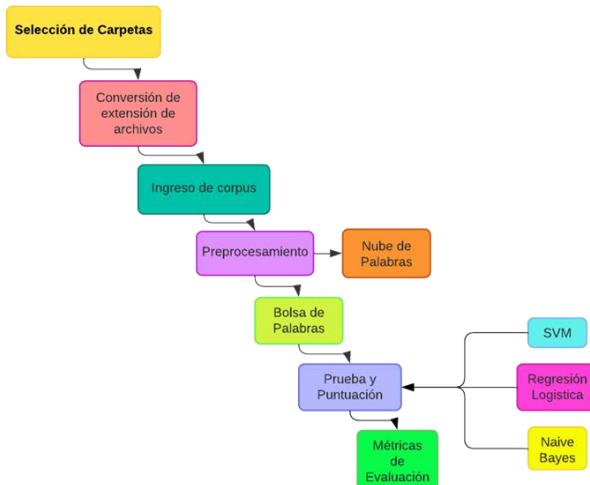


Fig. 1. Metodología de los experimentos realizados Se genera una bolsa de palabras con los archivos procesados y se realiza un análisis para discriminar los que tienen resultados bajos y elegir el que tenga mayor éxito de precisión, para esto se utilizaron los métodos de aprendizaje: Support Vector Machine (SVM), Regresión Logistica (RL) y Naive Bayes (NB), apoyados por las métricas de evaluación: Area bajo la curva (AUC), Recall, F1 y precisión.

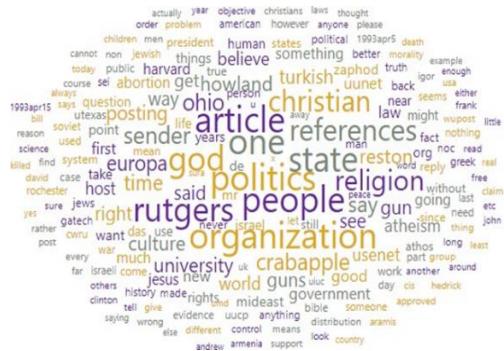


Fig. 2. Nube de palabras del proceso.

“soc.religion.christian”, “talk.religion.misc”, se optó por trabajar con estas seis carpetas y lograr minimizar el trabajo del equipo con el que setrabajó. En la Figura 1, se muestra el diagrama que señala la metodología implementada para realizar este estudio.

A continuación, se describen los componentes pertenecientes a la metodología. Para el ingreso de datos se tuvo que convertir su extensión a txt, ya que se desconocía el tipo de archivo que era. Posteriormente realizando los experimentos en Python, se le aplicó un preprocesamiento eliminando las stopwords, signos de puntuación y convirtiendo a minúsculas las palabras.

Finalizando esto, se crea una Nube de Palabras como se muestra en la Figura 2, para apoyar la mayor cantidad de menciones de palabras principales de los temas. Se genera una bolsa de palabras con los archivos procesados y se realiza un análisis para discriminar los que tienen resultados bajos y elegir el que tenga mayor éxito de

Tabla 2. Resultados del Test and Score de la carpeta con archivos crudos.

Modelo	AUC	F1	Precisión	Recall
SVM	0.805	0.418	0.766	0.444
Naive Bayes	0.956	0.805	0.819	0.807
Regresión Logística	0.965	0.871	0.871	0.871

Tabla 3. Resultados del Test and Score de la carpeta con archivos crudos sin stopwords.

Modelo	AUC	F1	Precisión	Recall
SVM	0.854	0.377	0.744	0.416
Naive Bayes	0.973	0.877	0.878	0.877
Regresión Logística	0.973	0.871	0.871	0.871

Tabla 4. Resultados del Test and Score de la carpeta sin etiquetas.

Modelo	AUC	F1	Precisión	Recall
SVM	0.602	0.130	0.494	0.206
Naive Bayes	0.908	0.634	0.680	0.629
Regresión Logística	0.922	0.734	0.736	0.734

Tabla 5. Resultados del Test and Score de la carpeta sin etiquetas sin stopwords.

Modelo	AUC	F1	Precisión	Recall
SVM	0.673	0.224	0.783	0.262
Naive Bayes	0.966	0.729	0.830	0.717
Regresión Logística	0.970	0.864	0.865	0.864

precisión, para esto se utilizaron los métodos de aprendizaje: Support Vector Machine (SVM), Regresión Logística (RL) y Naive Bayes (NB), apoyados por las métricas de evaluación: Área bajo la curva (AUC), Recall, F1 y precisión.

4. Resultados

De donde se descargó la base de datos de The 20 Newsgroups, contenía 2 carpetas, la primera eran los archivos completamente crudos sin modificar nada y la segunda donde se eliminaban las etiquetas que no se utilizaban de todos los archivos. Al observar esto, se optó por hacer el mismo experimento con ambas carpetas, es decir, probar los resultados cuando los datos se ingresan sin modificar y cuando se eliminan las stopwords.

Como cada carpeta tiene mil archivos aproximadamente, se realizaron los experimentos con los seis mil archivos, pero debido a que eran muchos archivos para el equipo con el que se trabaja, se optó por únicamente tomar 250 archivos de cada carpeta, teniendo un total de 1500 archivos.

De los experimentos se obtuvieron los resultados que se muestran en los cuadros a continuación, donde se puede observar que la carpeta con mejores resultados es la que contiene los archivos crudos y se le aplica la eliminación de stopwords (Tabla 3), la cual es con la que se trabajará para los siguientes experimentos.

5. Conclusión

Para la elaboración de este trabajo, se observa que se obtienen mejores resultados cuando se hace uso de las carpetas con todas las etiquetas de información de cada archivo, pero eliminando las stopwords, logrando alcanzar el 97.3% con la métrica de evaluación de área bajo la curva y los métodos de aprendizaje Naïve Bayes y Regresión Logística.

Haciendo la comparación de los resultados obtenidos en las tres investigaciones que se recabaron y que se muestran en el presente trabajo, se logró superar los resultados, teniendo en cuenta que es el mismo dataset y la misma metodología, variando el preprocesamiento a pesar de utilizar únicamente 3 métodos de aprendizaje y 4 métricas de evaluación, siendo posible trabajar con otros existentes.

Referencias

1. Escobar, H., Alcivar, M., Puris, A.: Aplicaciones de minería de datos en marketing. Revista Publicando, vol. 3, no. 8, pp. 503–512 (2016)
2. Sidow-Osman, A.: Data Mining Techniques: Review. International Journal of Data Science Research, vol. 2, no. 1, pp. 1–4 (2019)
3. Sánchez-Vera, M. D. M.: El pensamiento computacional en contextos educativos: una aproximación desde la Tecnología Educativa. Research in Education and Learning Innovation Archives, pp. 24–29 (2019) doi: 10.7203/realia.23.15635
4. Akef, I., Arango, J. S. M., Xu, X.: Mallet vs GenSim: Topic modeling for 20 news groups report. University of Arkansas at Little Rock, pp. 1–12 (2016)
5. Chandra, A.: Comparison of feature selection for imbalance text datasets. In: 2019 International Conference on Information Management and Technology (ICIMTech) IEEE., vol. 1, pp. 68–72 (2019) doi: 10.1109/ICIMTech.2019.8843773
6. Adi, A. O., Çelebi, E.: Classification of 20 news group with Naïve Bayes classifier. In: 2014 22nd Signal Processing and Communications Applications Conference (SIU), IEEE, pp. 2150–2153 (2014) doi: 10.1109/SIU.2014.6830688
7. Dubiau, L., Ale, J. M.: Análisis de sentimientos sobre un corpus en español: experimentación con un caso de estudio. In: XIV Argentine Symposium on Artificial Intelligence (ASAII) – JAIIIO, vol. 42, pp. 36–47 (2013)
8. Rosenbrock, G., Trossero, S., Pascal, A.: Técnicas de análisis de sentimientos aplicadas a la valoración de opiniones en el lenguaje español. In: XXVII Congreso Argentino de Ciencias de la Computación (CACIC), pp. 291–300 (2021)
9. Poccohuanca, Q., Edmit, O.: Integración de técnicas de deep learning y algoritmos de aprendizaje multi etiqueta para la Clasificación de Textos (2018)
10. Morales-Castro, J. C., Ledesma-Carrillo, L. M., Guzman-Cabrera, R.: Identificación de polaridad en Twitter usando validación cruzada. Identidad Energetica, vol. 4, pp. 87-91 (2022) https://www.researchgate.net/publication/357860394_Identificacion_de_polaridad_en_Twitter_usando_validacion_cruzada

Hsi Optical System by Conjugation of the Pupil with the Surface of a Refracting Mirror

Luis Arturo Tapia-Alarcón, Martín Alberto Vázquez-Castrejón,
J. Jesús Escobedo-Altorre, Omar Palillero-Sandoval

Universidad Autónoma del Estado de Morelos,
Centro de Investigación en Ciencias básicas y Aplicadas (CIICAp),
México

omar.palillero@uaem.mx

Abstract. In an optical imaging system with incoherent light, the study of spectral images is of great importance due to the large amount of information that can be obtained from an object in question. With the help of an object placed in the exit pupil, and following the theory of image formation, we show the design of an imaging system that allows to observe the optical spectrum of a test object, in this case a circular aperture and a filament of an incandescent lamp, through the conjugation of the pupil on a refracting mirror that, with a mechanical system to perform the scanning, we obtain a set of hyperspectral images.

Keywords: Spectral imaging, image processing, optical systems.

1 Introduction

The design of optical imaging systems has long seen a development in spectroscopic techniques as a non-invasive means of analysis and inspection, due to the possibility of obtaining information about the components of a sample based on the absorption of light [1-4]. With the support of visible/near infrared spectroscopic techniques and computer vision techniques, what is known as imaging spectroscopy has emerged [5-7]. Hyperspectral imaging is a map of light intensity that can be spread over one or more regions of the electromagnetic spectrum [8].

Hyperspectral images are a three-dimensional data set of an object or sample, these data contain spatial and spectral information. The three-dimensional data set is commonly referred to as a "hyperspectral cube". Data from a hyperspectral cube can reveal hidden information, such as the chemical or anatomical composition of an object [9]. Hyperspectral imaging is often used to detect physical and geometric features. Features such as color, size, shape, and texture.

It can also be used to extract intrinsic chemical and molecular information (such as water, fats, proteins, and other constituents) from a product. Hyperspectral imaging systems, also called HSI, have the capability of imaging more than 100 spectral bands. The main elements of a spectral imaging system are the following [10]: Point source of light, lenses and filters, image sensor, scanning system, and image processing hardware and software.

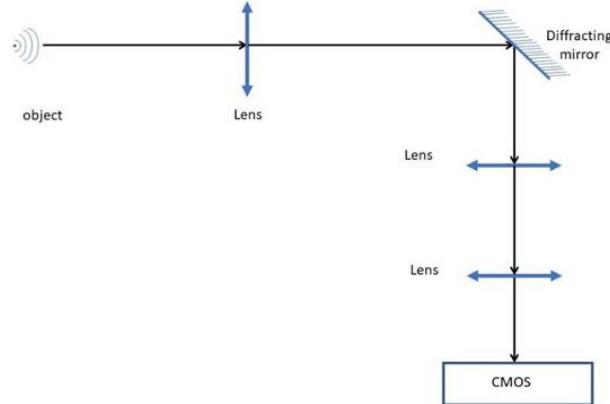


Fig. 1. Schematic of the imaging system.



Fig. 2. Results of frequency segmentation of light emitted by LEDs.

2 Image Formation Theory

An optical imaging system with modification in pupil function has been a widely used method to encode the wavefront, phased objects are commonly used to widen the field and inhibit optical aberrations, shadow objects to apodize and increase the resolution of images [11].

Particularly here we use this method to separate spectral images of a test object. Based on the theory of image formation, and applying the mathematical treatment for the case with incoherent light, it can be described mathematically by obeying the following equation:

$$g(x, y) = h(x, y) \times O_i(x, y), \quad (1)$$

where $g(x, y)$ corresponds to the image, $h(x, y)$ to the optical system and $O(x, y)$ to the object's intensity.

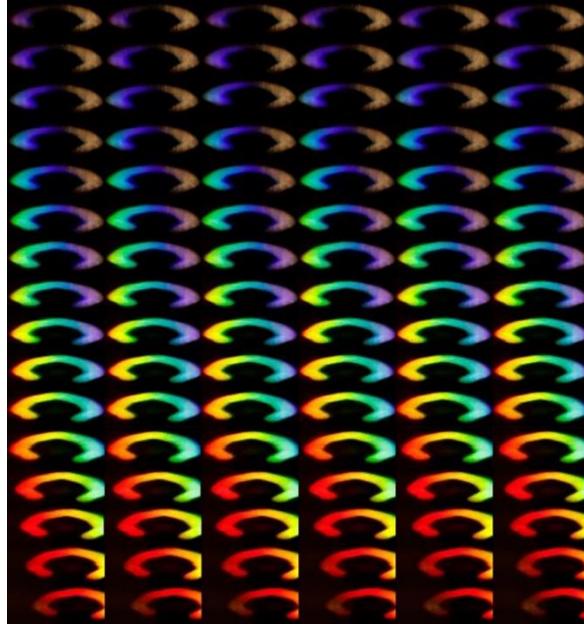


Fig. 3. Frequency segmentation of the incandescent filament.

3 Experiment Design and Results

3.1 Experiment Design

With the aid of a test object, placed in the exit pupil of the optical system, an imaging system is assembled to observe the optical spectrum of the object. For this work, a mirror containing a grating on its surface was used, which gives rise to a conjugation of planes to obtain the image formation, this method is known as pupil conjugation.

The arrangement in Figure 1 was tested using a circular aperture in the plane of the object to simulate a quasi-point source. A lens was placed behind the pupil to collimate the light rays coming from it and then a concave diffracting mirror was placed with the collimated light beam. Finally, with the reflection of the diffracted light, a telescopic lens system is mounted, and the image is formed on the CMOS detector.

A mechanical system performed the scanning in the image plane, the number of images obtained belong to hyperspectral images.

3.2 Results

The first experiment was performed with a white LED, which was placed in front of a pupil so that it could simulate a quasi-punctual source, from this test we obtained a set of images where the transition of the frequencies of the optical spectrum in which the LED emits can be clearly seen as in the cooler areas of the spectrum emits more

intensely, but in the area of the red spectrum, it is appreciated to a lesser extent. They were captured with a Canon T6 camera.

In experiment two an incandescent bulb is used, which contains a wider range of frequencies of the spectrum and when capturing them is visually appreciated with better contrast and more intensity in its filament, which allowed us to corroborate how the system is capable of obtaining a large number of images throughout the entire optical spectrum emitted by an object. We obtained 212 images in a 300 nm range, from 350 nm to 650 nm.

It is observed that there was a shift in the hyperspectral images obtained and it seems that all images are identical, however, due to the large amount of information only 96 of the 212 images are shown.

4 Conclusions

With an imaging system and the modification of the pupil, in this case conjugating the pupil planes with the mirror surface, it is possible to have a large number of images in the width of the visible light spectrum, as can be observed in the filament of the incandescent bulb, even the configuration would not change much if you want to measure near infrared or UV.

This technique allows spectral image analysis containing a large amount of information in areas such as the study of biological or chemical samples, in order to know their condition, defects or even if they are contaminated with any external agent because we can obtain spectral resolutions of 1.4 nm.

References

1. ElMasry, G., Sun, D. W.: Principles of hyperspectral imaging technology. Hyperspectral Imaging for Food Quality Analysis and Control, pp. 3–43 (2010) doi: 10.1016/B978-0-12-374753-2.10001-2
2. Du, C. J., Sun, D. W.: Learning techniques used in computer vision for food quality evaluation: A review. Journal of Food Engineering, vol. 72, no. 1, pp. 39–55 (2006) doi: 10.1016/j.jfoodeng.2004.11.017
3. Goodman, J. W. (2005). Introduction to Fourier optics. Roberts and Company publishers (1996)
4. Fowles, G. R., Lynch, D. W.: Introduction to modern optics. American Journal Physics, vol. 36, no. 8 (1968) doi: 10.1119/1.1975142
5. Zavala-De Paz, J., Isaza, C., Mosquera-Mosquera, J., Anaya-Rivera, E., Rizzo-Sierra, J., Palillero-Sandoval, O., Escobedo, J.: Non-invasive methodology for the study of wound healing process using spectral images. IEEE Latin America Transactions, vol. 18, no. 4, pp. 687–695 (2020) doi: 10.1109/TLA.2020.9082211
6. Isaza, C., Mosquera, J. M., Gómez-Méndez, G. A., Paz, Z. D., Jonny, P., Karina-Anaya, E., Palillero-Sandoval, O.: Development of an acousto-optic system for hyperspectral image segmentation. Metrology and Measurement Systems, vol. 26, no. 3 (2019) doi: 10.24425/mms.2019.129576
7. Du, C. J., Sun, D. W.: Learning techniques used in computer vision for food quality evaluation: a review. Journal of Food Engineering, vol. 72, no. 1, pp. 39–55 (2006) doi: 10.1016/j.jfoodeng.2004.11.017

Hsi Optical System by Conjugation of the Pupil with the Surface of a Refracting Mirror

8. Inoue, T., Hirai, A., Itoh, K., Ichioka, Y.: Compact spectral imaging system using liquid crystal for fast measurement. *Optical Review*, vol. 1, no. 1, pp. 129–131 (1994) doi: 10.1007/s10043-994-0129-9
9. Levenson, R. M.: Spectral imaging perspective on cytomics. *Cytometry Part A: the journal of the International Society for Analytical Cytology*, vol 69, no. 7, pp. 592–600 (2006) doi: 10.1002/cyto.a.20292
10. Qiao, J., Ngadi, M. O., Wang, N., Gariépy, C., Prasher, S. O.: Pork quality and marbling level assessment using a hyperspectral imaging system. *Journal of Food Engineering*, vol. 83, no. 1, pp. 10–16 (2007) doi: 10.1016/j.jfoodeng.2007.02.038
11. Palillero-Sandoval, O., Márquez-Aguilar, P. A., Berriel-Valdos, L. R.: Engineering of apodizer filters in the optical imaging using a set of phase plates. *Optical Engineering*, vol. 55, no. 10 (2016) doi: 10.1117/1.OE.55.105103

Development and Evaluation of a RapidPlan-Based Semi-Automated Learning System for Prostate Cancer Treatment Planning

Sandra Arrieta¹, Alberto Hardy¹, Nestor Aragón²,
Omar Hernández²

¹ Universidad Autónoma del Estado de México,
Mexico

² Centro Médico ABC,
Mexico

san.arrimar@gmail.com, hardy.alberto@yahoo.com,
naragonm@hotmail.com, johernandezo@abchospital.com

Abstract. Prostate cancer is an increasingly common disease in Mexico, and its treatment with external beam radiotherapy is becoming more frequent. Intensity modulated radiation therapy (IMRT) and volumetric intensity modulated arc therapy (VMAT) techniques use inverse planning, which depends on the experience of the planner or medical physicist. To improve treatment and planning time plans, semiautomated learning, or Knowledge Based Planning (KBP) systems have been developed. The RapidPlan KBP system (Varian Medical Systems, Palo Alto, CA) is a system that uses information from previous treatment plans to generate customized plans from dose volume histogram estimate (DVHE) bands for a new treatment plan. A total of 35, two stage prostate cancer plans were recorded by ABC Medical Center database and were applied to train and test the semiautomated model. Seven new plans were created from this RapidPlan (RP) model, which were compared with those obtained by a manual planner (MP), thus verifying the veracity and efficiency of the tool. The Wilcoxon signed rank test was performed between PM and PR for the dosimetric parameters, and $p < 0.05$ was statistically significant. The results are very comparable to those obtained by the planner, and it is concluded that the model is effective in generating clinically acceptable and high-quality treatment plans, also reducing planning times.

Keywords: Prostate cancer, automatic learning system, RapidPlan.

1 Introduction

Cancer is a disease that continues to be the leading cause of death worldwide, with almost 10 million deaths attributed to this disease in 2020, according to the World Health Organization (WHO) [1]. In Mexico, prostate cancer (PC) is the leading cause of malignant tumor in the male population over 60 years of age, according to records presented by the National Institute of Statistics and Geography (INEGI) [2], which is commonly treated with radiotherapy.

A safe method in the treatment of PC for dose escalation is by employing the Elekta IMRT or Varian RapidArc VMAT techniques [3, 4] which allow a homogeneous radiation dose to be administered to the palpable tumor volume (PTV), while limiting the dose to organs at risk (OAR), such as the bladder, rectum, femoral heads, bowel, and penile bulb [5], through the dose volume histogram (DVH) at the time of planning. However, there is no standard metric to objectively assess the quality of a treatment plan that relates the dose administered to potential treatment success and adverse effects known in advance [6].

Treatment planning for prostate cancer is a crucial process in which the aim is to obtain the best quality [7] and the best treatment for the patient with the lowest possible risk of adverse side effects [8]. Currently, planning based on the experience of a planner is the most common way of performing the treatment plan [9], but its quality and efficiency can vary widely [10]. Currently, developing an IMRT and VMAT plan involves starting from scratch and optimizing it using a time consuming and subjective trial and error approach [11].

Moreover, this approach may not achieve the optimization needed to optimally preserve OARs. The entire IMRT or VMAT treatment planning process can take several hours per case to reach a clinically acceptable plan [12]. This process involves finding a balance between the conflicting constraints of achieving homogeneous coverage of the prostate target volume and minimizing dose to adjacent normal critical structures [13]. Although a plan may be considered acceptable from a clinical standpoint, it may be far from optimal if dose to normal tissue is not minimized as much as possible [11].

To address this variability in treatment plan quality and improve the efficiency of the planning process, semiautomated learning systems using knowledge-based planning (KBP) [14, 16], such as RapidPlan (RP), have been developed. These systems use information from previous treatment plans to generate personalized and optimized plans for new patients, regardless of the planner performing the plan [9, 10].

In this context, the aim of this work is to develop a planning model based on prior knowledge of patient treatment plans and to compare the results of treatment plans generated by the semiautomated learning system (RP) with manual plans (MP), both in terms of treatment plan quality and planning time. The results obtained could improve the efficiency and quality of PC treatment planning, reduce time and ultimately improve patient care.

2 Related Work

The clinical implementation of IMRT and VMAT radiotherapy techniques increased considerably in the last two and last decade, respectively [4]. Both techniques aim to provide the optimal dose distribution calculated by an inverse planning process. To achieve this, optimization engines use numerical targets derived from clinical objectives, i.e., dose volume relationships linked to the management of tumor control probabilities and healthy tissue complications [14].

The quality of the plan is highly dependent on the knowledge and experience of the planners, as well as the institutional resources available to them [17]. Reverse planning can be a time consuming process [18]. The reverse planning process used in IMRT and

VMAT planning can make it difficult for inexperienced or inexperienced planners to know whether a plan is fully optimized or whether it can be further improved by spending more time and effort on it [9]. This, combined with the need to reduce planning time per patient given limited resources, can lead to significant differences in plan quality between institutions delivering radiation therapy [19].

In the recent past, different avenues of research were investigated, such as planning automation [1020] knowledge-based planning (KBP) [14] or multicriteria optimization [21]. Semiautomated learning systems using knowledge-based planning (KBP) [14], such as Auto Planning from Pinnacle (Phillips Healthcare) [15, 22] and RapidPlan (RP) from Eclipse (Varian Medical Systems, Palo Alto, CA) [9, 16], have been developed to address variability in treatment plan quality and improve the efficiency of the planning process [23].

The KBP approach consists of predictive DVH modeling based on statistical analysis of historical data and machine learning methods [5, 14], i.e., good quality treatment plans [9, 24]. These systems use information from previous treatment plans to generate personalized and optimized plans for new patients [25], regardless of the performing planner [9, 10].

KBP consists of building predictive DVH models and optimal dosimetric targets based on statistical analysis using a data library containing previously planned DVHs from historical treatment plans on patients, which have good quality [18, 19, 26, 27]. A training process aims to build a mathematical model, which can be used to predict, for any new case (patient) with its own specificity, the optimal dose distribution [16].

The RapidPlan KBP system is used to develop a model capable of producing treatment plans with IMRT and VMAT techniques. The RP system is a commercial KBP tool, implemented in the Eclipse treatment planning system (TPS) from Varian [28]. Which has been widely studied in recent years, applied in different sites: liver [23], pelvis [4, 29] head and neck [14], breast [31], and others. In summary, the evidence from these studies indicated that the use of PR allowed an overall improvement in the interpatient consistency of treatment plans, their intrinsic quality, and the efficiency (time and workflow) of the process [19].

3 Method

3.1 Patients

A sample of 35 patients with stage II PC was taken, that is, if prophylactic pelvic lymph node irradiation is prescribed. The prescription dose is 46 Gy over 5 weeks to prostate and proximal seminal vesicles, followed by a 32 Gy boost dose to the prostate, where IMRT or VMAT techniques were used.

Permission was obtained from the CMABC for the use of these retrospective cases in this study, and cases were anonymized prior to use. Each treatment plan includes the computed tomography (CT) data set, PTV and OAR contours, beam geometry specifications, beam intensity (fluence) maps, and dose distributions.

At this medical center, seven coplanar beam angles are typically used for IMRT (0° , 51° , 102° , 153° , 204° , 255° and 306°), and where necessary, nine coplanar fields (20° , 60° , 100° , 140° , 140° , 180° , 220° , 260° , 300° and 340°) and two CW (clockwise) and

Table 1. CMABC prostate IMRT/VMAT protocol with dose volume constraints. All constraints are based on a target dose of 78 Gy.

Genitourinario, GU (1.8-2.0 Gy/fx)		
Critical structure	Dose (Gy)	% Volume
Bladder	40	50
Bladder	65	25
Bladder (Davg)	45	
Rectum	40	45
Rectum	65	15
Rectum (Davg)	50	
Lt femoral head	50	5
Rt femoral head	50	5
Penile bulb (Dmax)	50	
Small bowel	45	<195 cc

CWW (counterclockwise) VMAT arcs were used. The treatment was delivered using an Elekta Clinac iX linear accelerator and a photonbeam energy of 6 MV and a Novalis TX linear accelerator with a photon beam energy of 6 MV.

3.2 RapidPlan Model Creation

Using the Eclipse TPS version 16.01.10. The model was then created, extracting the information from the previous treatment plans. Additional configurations were performed, such as the definition of the model ID, the version of the DVH estimation algorithm, the anatomical region of the model, the training status of the model and the model description. After the configuration stage, we proceeded to define the structures used in the semiautomated learning planning model.

These structures were divided into two main categories: target structures (PTV) and organ at risk (OAR) structures. The PTVs were created to delineate the region that was to receive the radiotherapy dose. In the case of PC, PTV structures were defined to encompass the prostate and involved nodes. Among the OARs, the femoral heads, penile bulb, bowel, rectum, and bladder were delineated.

Once the set of structures and radiation beam configurations were created, we proceeded to feed the RP model by adding plans to it. The DVH estimation model extracts the data from the treatment plans, allowing the model to be used independently without the need to access the original plans used to train it. The next step is to train and verify the model.

During the training process, the system processes the plan data extracted from the training plans. The model uses semiautomatic learning, machine learning and statistical techniques to map the structure and geometry information of the plans, such as relative distances between the OARs and the target organ, OAR volumes, etc., to the corresponding dosimetric information, such as DVH curves. Their characteristics

have been previously described in detail in [10, 11, 27, 29]. Subsequently, this information was evaluated and reviewed by the planner, in which data that could be outside the model criteria and affect the good performance of the model were discarded.

3.3 Evaluation of the Quality of Treatment Plan

Table 1 shows the prostate protocol for IMRT and VMAT used at this institution to specify dose volume constraints for critical structures. The protocol is similar to those established by the Radiation Oncology and Therapy Group (RTOG) and Quantitative Analyses of Normal Tissue Effects in the Clinic (QUANTEC) for CP IMRT and VMAT clinical trials. Typical clinical practice strives to deliver a prescription dose of at least 95% (or higher) of the PTV without exceeding dose constraints to OAR.

In this study, a total of seven new treatment plans were developed, where the quality of each treatment plan was assessed by comparing the DVH of the new semiautomated RP plan with that of the original MP plan developed manually by a (human) planner. A comparison of the various DVH cutoff points considered dose to volume percentage coverage (D_x , which is the dose at the highest $x\%$ volume) for PTV and two normal structures (i.e., bladder and rectum) [11].

The cutoff points for PTV were D98, D95, and D2. Specifically, D2 was used to quantify the target maximal dose. For both bladder and rectum, the respective cut off points were assessed at D40, D65 and D_{max} of each. Only the constraints of seven major structures were selected and imported, including the PTV, bladder, rectum, both femoral heads, bowel, and penile bulb. Each plan was normalized to deliver the prescription dose to approximately 95% of the PTV.

Treatment plans were evaluated for relative percentage differences at specific DVH points using the following equation:

$$\% \text{Diff} = \frac{D_{vol \text{RP}} - D_{vol \text{PM}}}{D_{vol \text{PM}}} \times 100. \quad (1)$$

A positive percentage difference indicates that the new plan, RP, has a reduced dose compared to the original plan, MP. For a critical structure, such a negative percentage difference indicates an improvement, i.e., a higher dose economy. However, for PTV results, on the contrary, a positive result in the percentage difference indicates higher dose coverage in the target organ, which is an indicator of improvement, since one wants to improve the dose to PTV and reduce the dose to OAR.

The Wilcoxon signed rank test was performed between MP and RP for the dosimetric parameters described above. To perform these tests, the statistical package for social sciences (SPSS 25.0; SPSS Inc., Chicago, IL, USA) was used to perform these tests and $p < 0.05$ was considered statistically significant.

3.4 Patient Specific Quality Control (PSQC)

Quality control of the patient specific treatment plans (PSQC) obtained by RP was performed using an Octavius II + PTW 729 manikin and the MEPHYSTO program, VeriSoft 5.1 version (5.1.0.35) to compare the results obtained with those calculated by the TPS. PSQC is performed prior to IMRT and VMAT treatment to ensure that the planned (calculated) treatment plan matches or is comparable to that which will be given

to the patient (measured). This ensures that the treatment plan is clinically acceptable. This quality control was performed using the criteria of $\Delta D=3\%$ in dose and $\Delta d=3$ mm in distance. According to these criteria, it is established that at least 90% of the evaluated points must meet the gamma index (GI) criteria to pass the test [32].

4 Results

Although the results of the seven new cases planned by MP and RP are summarized, three of the seven cases were selected to further illustrate the comparison between the new semi automatically generated plan and the DVHs of the original manual plan. Fig. 1 shows the comparison between the DVH obtained using the RP model and the DVH of the manually generated plan by the planner for case 1, which is one of the best seven cases selected.

A dose distribution in the PTV with better coverage and a comparable curve falloff between the new plan, RP (lines with square), and the original plan, MP (lines with triangle), as well as considerably higher dose savings in both bladder and rectum are observed. This identification scheme will remain constant for all cases analyzed. The DVH of the femoral heads, penile bulb and bowel are not traced to make it easier to visualize the PTV, bladder and rectum.

For case 1, PTV coverage in the new plan is approximately equal to that in the original plan; the relative percentage differences in D98, D95, and D2 were 0.68%, 0.24%, and -0.82%, respectively. For the rectum, the new plan consistently demonstrated large additional dose savings, as shown by the new plan's boxed curve moving steadily to the left of the original plan's triangle line.

For example, the new plan reduced the dose in straight V40, V65, and Davg by 17.11%, 3.99%, and 1.79%, respectively. Similar dose savings were also demonstrated in the bladder. Detailed cut point values for all cases are reported below in tables. In summary, case 1 illustrates that the new plan has very comparable PTV coverage and substantial dose savings in both the bladder and rectum.

The DVH plot for case 4 is shown in Fig. 2 and is representative of most of the seven cases, with very comparable dose distributions to the PTV, bladder and rectum. Five of the seven new plans had comparable DVH results relative to the original clinical plan. Fig. 3 illustrates the one case (case 3), which had comparable PTV coverage but a higher dose for both bladder and rectum compared to the original plan.

However, these normal structure doses are still clinically acceptable as they are well below the dose volume limitations established in the protocol. The PTV results are very comparable, with relative percentage differences of 8.83%, 2.81% and -5.55% in D98, D95 and D2, respectively, showing an improvement in the results for PTV obtained by the RP plan. However, the dose in bladder at V40, V65 values indicated an increase in preservation by 5.44%, 41.30% and a decrease in Davg of 4.82%. Similarly, the indicated rectal dose increased for V40 by 45.06%, V65 by 64.15% and Davg decreased by 2.69%.

Although there is substantially higher relative percentage dose for both rectal and bladder dose in the RP, note that, in terms of absolute dose to volume cutoff points, the critical structure doses would still be clinically acceptable as they are well below the dose constraints set forth in the protocol (see Table 1).

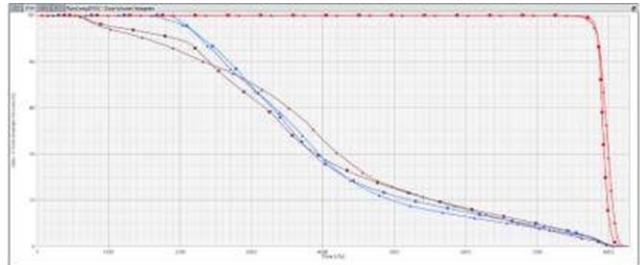


Fig. 1. Comparison of the DVH for case 1. The new plan MP (triangle) and the one RP model (square) were compared. Case 1 is one of the best of the seven cases, demonstrated comparable PTV coverage and considerably higher dose savings in several OARs.

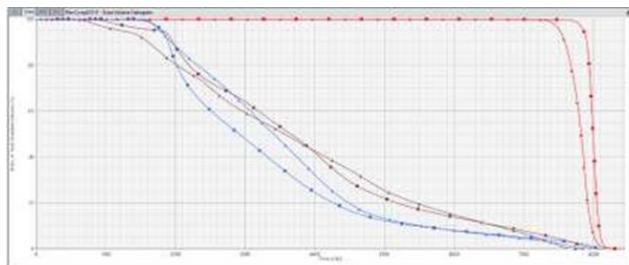


Fig. 2. DVH comparison for case 4. This case is representative of the majority of the seven cases. This graph shows that the dose to the PTV, rectum and bladder in the new plan (squares) are very comparable with the manual plan (triangles).

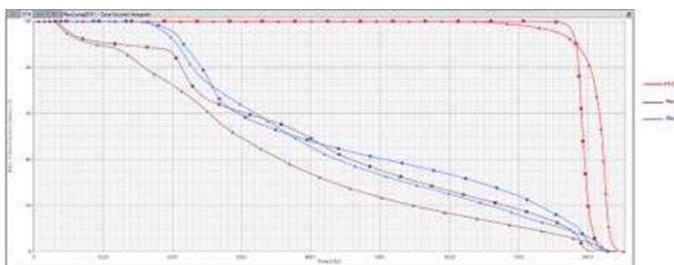


Fig. 3. Comparison of the DVH for case 3. Comparison of the plan performed by the planner (triangle) and the one performed by the RapidPlan model (square) illustrates comparable PTV coverage, but higher dose for both bladder and rectum.

A detailed comparison of the relative percentage differences [Eq. (1)] in specific dose to volume values for PTV for the 7 new plans made by RP and MP is shown in Table 2I. A positive value in PTV indicates that the plan by RP has higher PTV coverage compared to the MP. The mean percentage differences for the seven cases (mean \pm standard deviation) in D98, D95 and D2 are $3.10\% \pm 3.53\%$, $1.76\% \pm 1.99\%$ and $-0.95\% \pm 2.60\%$, respectively.

On average, the new semiautomated plan can achieve PTV coverage very comparable to the original plan (Table 2). Most of the new MP plans and PRs, met the prescribed requirements for the target organs. Overall, the pass rate for the dose criteria

Table 2. Percentage difference in PTV coverage between the treatment plan obtained by the MP and the semi-automated RP learning model.

Cases	D98	D95	D2
1	0,69	0,24	-0,81
2	5,12	4,55	1,78
3	9,69	2,89	-5,25
4	5,03	4,56	0,83
5	1,60	1,06	-3,03
6	0,66	0,41	-0,26
7	-1,08	-1,40	0,12
Average	3,10	1,76	-0,95
Std. Dev.	3,53	1,99	2,60
p-value	0,063	0,091	0,499

Table 3. Percentage difference in rectum doses between the treatment plan obtained by the MP and the semi-automated RP learning model.

Cases	V40	V65	Davg=40 Gy
1	-17,11	-3,99	-1,79
2	3,71	30,68	-0,44
3	45,06	64,15	-2,69
4	-1,62	-0,84	2,07
5	12,85	-0,57	2,49
6	-10,06	-27,12	-7,07
7	-1,59	-17,32	-2,07
Average	4,46	6,43	-1,36
Std. Dev	20,28	31,15	3,23
P value	0,866	0,612	0,310

and the dose distribution in the target organs were similar in the two groups of plans. In addition, for the Wilcoxon test, we found p-value = 0.063, 0.091, 0.499 > 0.005, so no significant statistical difference was found between PR and MP for PTV. Table 3. shows the percentage differences between the MP and RP plan for rectal dose at V40, V65 and Davg= 40 Gy for all seven cases.

For OAR, a negative value indicates an improvement, where the new plan has a higher rectal sparing dose compared to the original plan. For the seven cases, the mean and standard deviation of the percentage dose differences to the rectum for V40, V65 and Davg is $4.46\% \pm 20.28\%$, $6.43\% \pm 31.15\%$ and $-1.36\% \pm 3.23\%$, respectively.

Four of the seven newplans (cases 1, 4, 6, 7) have higher rectal dose savings compared to the original plan, while two (cases 2, 5) are quite comparable to the original

plan. However, case 3 on the contrary does not show an improvement in the rectal plan, in all three constraints evaluated it is clinically rejected. The new plans made by the MP and the RP met the prescribed requirements for OARs. Overall, the pass rate for the dose criteria and rectal dose distribution were similar in the two groups of plans. In addition, for the Wilcoxon test, for V40, V65 and Davg, p-value = 0.866, 0.612, 0.310 > 0.005, respectively, so no significant statistical difference was found between RP and MP for rectum.

Finally, Table 4 shows the percentage differences between RP and MP for bladder dose at V40, V65 and Davg = 40 Gy for all seven cases. A negative value indicates an improvement, where the new plan has a higher bladder dose savings compared to MP. For the seven cases, the mean and standard deviation of the percentage bladder dose differences for V40, V65 and Davg are $-1.79\% \pm 15.72\%$, $21.15\% \pm 16.44\%$ and $-1.79\% \pm 6.51\%$, respectively.

Three of the seven PR plans (cases 1, 2 and 4) have a substantially lower dose to the bladder, while three (cases 5, 6 and 7) are very comparable with the MP plan. For case 3, the percentage differences for V40, V65 and Davg may appear high, but the absolute dose values are still clinically acceptable as they are below the dose constraints set in the original protocol (see Table 1).

Overall, the pass rate for the dose criteria and bladder dose distribution were similar in the two plan groups. In addition, for the Wilcoxon test, for V40 and Davg we found p-value = 1.000 and $0.397 > 0.005$, so no significant statistical difference was found between RP and MP for bladder in these DVH cutoffs. However, for rectum V65 the p-value = $0.018 < 0.05$, indicating that there is a significant difference between the result obtained by MP and RP.

The results of the quality control of the patient specific treatment plans (PSQC) obtained passed the criteria of $\Delta D=3\%$ in dose and $\Delta d=3$ mm in distance. According to these criteria, it is established that at least 90% of the evaluated points must meet the gamma index criteria to pass the test. Most of the plans scored above 95%, and all passed the GI criterion of 90%.

It is important to note that, on average, the treatment plan using the RP model could be obtained in approximately 40 minutes total for each of the seven cases evaluated. This plan consists of the creation of a Phase II plan, for an irradiation of 46 Gy to prostate and nodes and a second irradiation to prostate of 32 Gy, with a total dose of 78 Gy. On the other hand, the treatment plans made by the expert planner required approximately 3 to 4 hours of manual work, although this time may vary depending on the planner.

In terms of time optimization, the RP model shows a significant advantage, since while the dosimetrist can perform one plan, the semiautomated learning model can generate 4 to 6 clinically acceptable treatment plans in the same period.

5 Conclusions

The knowledge-based approach, using clinically approved pretreatment plans, is shown to be effective in generating clinically acceptable, high quality treatment plans. This semiautomated approach has the potential to improve the efficiency of the treatment planning process while ensuring the quality of the plans generated.

Table 4. Percentage difference in bladder dose between the treatment plan obtained by the MP and the semiautomatic RP learning plan.

Cases	V40	V65	Davg=45 Gy
1	-5,04	14,56	-1,34
2	-24,46	29,77	-10,23
3	5,44	41,30	-4,82
4	-20,38	5,37	-7,73
5	15,14	42,54	9,07
6	2,64	5,56	0,42
7	14,14	8,96	2,12
Average	-1,79	21,15	-1,79
Std. Dev.	15,72	16,44	6,51
p-value	1,000	0,018	0,397

The results provide reassurance and reliability in the RP model, as no statistically significant difference was found between one form of planning and another, meeting the quality criteria for radiotherapy treatment plans. In addition to the reduction in planning time. It is important to note that the RP model will continue to improve as more patients are added to the model. The greater the number of patients, the greater the learning capability of the model and the better estimates of DVH curves will be obtained with RapidPlan.

References

1. Organización Mundial de la Salud: Cáncer. <https://www.who.int/es/news-room/fact-sheets/detail/cancer>
2. INEGI: Estadísticas a propósito del día mundial contra el cáncer. Comunicado de Prensa, no. 105/21
3. Pelayo-Besa, D. C., Rosso, R., Bustos, M., Borghero, Y., Trucco, C., Mac-Namara, M.: Tratamiento del cáncer de próstata con radioterapia por modulación de intensidad, primera experiencia en Chile. Revista médica de Chile, vol. 139, no. 11, pp. 1451–1457 (2011) doi: 10.4067/S0034-98872011001100009
4. Teoh, M., Clark, C. H., Wood, K., Whitaker, S. Nisbet, A.: Volumetric modulated arc therapy: A review of current literature and clinical use in practice. The British Journal of Radiology, vol. 84, no. 1007, pp. 965–e225 (2011) doi: 10.1259/bjr/22373346
5. O’Grady, F. T., Geng, H., Huang, M., Giaddui, T., Zong, H.: Experience based quality control in IMRT Treatment Planning of high risk post prostatectomy prostate cancer with RapidPlan. Master of Medical Physics Capstone Projects 1, University of Pennsylvania (2017) http://repository.upenn.edu/medical_physics_capstone
6. Chang, A. T. Y., Hung, A. W. M., Cheung, F. W.K., Lee, M. C. H., Chan, O. S. H., Philips, H., Cheng, Y. T., Ng, W. T.: Comparison of planning quality and efficiency between conventional and knowledge-based algorithms in nasopharyngeal cancer patients using

- intensity modulated radiation therapy. International Journal of Radiation Oncology Biology Physics, vol. 95, no. 3, pp. 981–990 (2016) doi: 10.1016/j.ijrobp.2016.02.017
- 7. Bakiu, E., Telhaj, E., Kozma, E., Ruçi, F., Malkaj, P.: Comparison of 3D CRT and IMRT treatment plans. Acta Informatica Medica, vol. 21, no. 3, pp. 211–212 (2013) doi: 10.5455/aim.2013.21.211-212
 - 8. Mavroidis, P., Komisopoulos, G., Buckey, C., Mavroeidi, M., Swanson, G. P., Baltas, D., Papanikolaou, N., Stathakis, S.: Radiobiological evaluation of prostate cancer IMRT and conformal-RT plans using different treatment protocols. Physics in Medicine & Biology, vol. 40, pp. 33–41 (2017) doi: 10.1016/j.ejmp.2017.07.003
 - 9. Fogliata, A., Cozzi, L., Stravata, A., Lobefalo, F., Franzese, C., Franceschini, D., Tomatis, S., Scorsetti, M.: RapidPlan knowledge-based planning: iterative learning process and model ability to steer planning strategies. Radiation Oncology, vol. 14, pp. 1–12 (2019)
 - 10. Scaggion, A., Fusella, M., Roggio, A., Bacco, S., Pivato, N., Andrea-Rossato, M., Arana-Peña, L. M., Paiusco, M.: Reducing inter and intraplanner variability in radiotherapy plan output with a commercial knowledge-based planning solution. Physica Medica, vol. 53, pp. 86–93 (2018) doi: 10.1016/j.ejmp.2018.08.016
 - 11. Chanyavanich, V., Das, S. K., Lee, W. R., Lo, J. Y.: Knowledge-based IMRT treatment planning for prostate cancer. Medical Physics, vol. 38, no. 5, pp. 2515–2522 (2011) doi: 10.1118/1.3574874. PMID: 21776786
 - 12. Lu, R., Radke, R. J., Happerset, L., Yang, J., Chui, C. S., Yorke, E., Jackson, A.: Reduced-order parameter optimization for simplifying prostate IMRT planning. Physics in Medicine & Biology, vol. 52, no. 3, pp. 849–870 (2007) doi: 10.1088/0031-9155/52/3/022
 - 13. Samir, F., Meaz, T. M., Hussiny, F. A., Ahmed, A. A., Mahmoud, A. A., Refaat, T., Gawis, A., Abouegylah, M.: Analytical dosimetric study of intensity-modulated radiotherapy (IMRT) and volumetric modulated arc therapy (VMAT) for prostate cancer. Journal of Cancer Research and Clinical Oncology, vol. 149, no. 9, pp. 6239–6246 (2023) doi: 10.1007/s00432-023-04586-5
 - 14. Smith, A., Granatowicz, A., Stoltenberg, C., Wang, S., Liang, X., Enke, C. A., Wahl, A. O., Zhou, S., Zheng, D.: Can the student outperform the master? A plan comparison between pinnacle autopanning and eclipse knowledge-based RapidPlan following a prostate bed plan competition. Technology in Cancer Research & Treatment, vol. 18, pp.1–8 (2019) doi: 10.1177/1533033819851763
 - 15. Philips: Pinnacle³ 9.10 con Auto Planning, Planificación acelerada de IMRT yVMAT <https://www.philips.es/healthcare/product/HCNOCTN195/pinnacle3autoplanning>
 - 16. Varian Medical Systems: Eclipse photon and electron algorithms reference guide. Palo Alto, CA, Estados Unidos de América (2001)
 - 17. Jihong, C., Kaiqiang, C., Yitao, D., Xiuchun, Z., Yanyu, C., Penggang, B.: Evaluation of auto planning in VMAT for locally advanced nasopharyngeal carcinoma. Scientific Reports, vol. 12 (2022) doi: 10.1038/s41598-022-07519-3
 - 18. Chua, L. M. H., Pang, E. P. P., Master, Z., Sultana, R., Tuan, J. k. L., Bragg, C.: Dosimetric comparison of RapidPlan and manually optimised volumetric modulated arc therapy plans in prostate cancer. Journal of Radiotherapy in Practice, vol. 20, no. 3, pp. 257–264 (2021) doi: 10.1017/S1460396920000345
 - 19. Schubert, C., Waletzko, O., Weiss, C., Voelzke, D., Toperim, S., Roeser, A., Puccini, S., Piroth, M., Mehren, C., Kueter, J. D., Hierholz, K., Gerull, K., Fogliata, A., Block, A., Cozzi, L.: Intercenter validation of a knowledge-based model for automated planning of volumetric modulated arc therapy for prostate cancer. The experience of the German RapidPlan Consortium. PLoS One, vol. 12, no. 5, pp. e01178034 (2017) doi: 10.1371/journal.pone.0178034

20. Fusella, M., Scaggion, A., Pivato, N., Rossato, M. A., Zorz, A., Paiusco, M.: Efficiently train and validate a RapidPlan model through APQM scoring. *Medical Physics*, vol. 45, no. 6, pp. 2611–2619 (2018) doi: 10.1002/mp.12896
21. Park, J., Park, J., Oh, S., Yea, J. W., Lee, J. E., park, J. W.: Multicriteria optimization for planning volumetric modulated arc therapy for prostate cancer. *PLoS One*, vol. 16, no. 9, pp. e0257216 (2021) doi: 10.1371/journal.pone.0257216
22. Cilla, S., Romano, C., Morabito, V. E., Macchia, G., Buwenge, M., Dinapoli, N., Indovina, L., Strigari, L., Morganti, A. G., Valentini, V., Deodato, F.: Personalized treatment planning automation in prostate cancer radiation oncology: a comprehensive dosimetric study. *Frontiers in Oncology*, vol. 11 (2021) doi: 10.3389/fonc.2021.636529
23. Yu, G., Li, Y., Feng, Z., Tao, C., Yu, Z., Li, B., Li, D.: Knowledge-based IMRT planning for individual liver cancer patients using a novel specific model. *Radiation Oncology*, vol. 13, no. 52 (2018) doi: 10.1186/s13014-018-0996-z
24. Shiraishi, S., Moore, K. L.: Knowledge-based prediction of three-dimensional dose distributions for external beam radiotherapy. *Medical Physics*, vol. 43, no. 1, pp. 378 (2016) doi: 10.1111/1.4938583
25. Voet, P. W. J., Dirkx, M. L. P., Breedveld, S., Fransen, D., Levendag, P. C., Heijmen, B. J. M.: Toward fully automated multicriterial plan generation: a prospective clinical study. *International Journal of Radiation Oncology, Biology, Physics*, vol. 85, no. 3, pp. 866–872 (2013) doi: 10.1016/j.ijrobp.2012.04.015
26. Hansen, C. R., Bertelsen, A., Hazell, I., Zukauskaite, R., Gyldenkerne, N., Johansen, J., Eriksen, J. G., Brink, C.: Automatic treatment planning improves the clinical quality of head and neck cancer treatment plans. *Clinical and Translational Radiation Oncology*, vol. 1, pp. 2–8 (2016) doi: 10.1016/j.ctro.2016.08.001
27. Wang, J., Hu, H., Yang, Z., Chen, X., Wu, Z., Yu, X., Guo, X., Lu, S., Li, K., Yu, G.: Is it possible for knowledge-based planning to improve intensity modulated radiation therapy plan quality for planners with different planning experiences in left sided breast cancer patients? *Radiation Oncology*, vol. 12, no. 85, 1–8 (2017) doi: 10.1186/s13014-017-0822-z
28. Varian a Siemens Healthineers Company <https://www.varian.com/es/products>
29. Hussein, M., South, C. P., Barry, M. A., Adams, E. J., Jordan, T. J., Stewart, A. J., Nisbet, A.: Clinical validation and benchmarking of knowledge-based IMRT and VMAT treatment planning in pelvic anatomy. *Radiotherapy and Oncology*, vol. 120, no. 3, pp. 473–479 (2016) doi: 10.1016/j.radonc.2016.06.022
30. Swamidas, J., Pradhan, S., Chopra, S., Panda, S., Gupta, Y., Sood, S., Mohanty, S., Jain, J., Joshi, K., Ph, R., Gurram, L., Mahantshetty, U., Agarwal, J. P.: Development and clinical validation of knowledge-based planning for volumetric modulated arc therapy of cervical cancer including pelvic and para aortic fields. *Physics and Imaging in Radiation Oncology*, vol. 18, pp. 61–67 (2021) doi: 10.1016/j.phro.2021.05.004
31. Fogliata, A., Nicolini, G., Bourgier, C., Clivio, A., De Rose, F., Fenoglietto, P., Lobefalo, F., Moncusso, P., Tomatis, S., Vanetti, E., Scorsetti, M., Cozzi, L.: Performance of a knowledge-based model for optimization of volumetric modulated arc therapy plans for single and bilateral breast irradiation. *PLoS One*, vol. 10, no. 12, pp. e0145137 (2015) doi: 10.1371/journal.pone.0145137
32. Low, D. A., Harms, W. B., Mutic, S., Purdy, J. A.: A technique for the quantitative evaluation of dose distributions. *Medical Physics*, vol. 25, no. 5, pp. 656–661 (1998) doi: 10.1111/1.598248

Electronic edition
Available online: <http://www.rcs.cic.ipn.mx>



<http://rcs.cic.ipn.mx>



Centro de Investigación
en Computación