



UTMACH

FACULTAD DE CIENCIAS AGROPECUARIAS

CARRERA DE MEDICINA VETERINARIA

Caracterización del perfil citológico de la mucosa vaginal durante el ciclo estral en perras con ayuda de inteligencia artificial.

**COELLO LUDEÑA MARIA ALEJANDRA
MEDICA VETERINARIA**

**MACHALA
2024**



UTMACH

FACULTAD DE CIENCIAS AGROPECUARIAS

CARRERA DE MEDICINA VETERINARIA

Caracterización del perfil citológico de la mucosa vaginal durante el ciclo estral en perras con ayuda de inteligencia artificial.

**COELLO LUDEÑA MARIA ALEJANDRA
MEDICA VETERINARIA**

**MACHALA
2024**



UTMACH

FACULTAD DE CIENCIAS AGROPECUARIAS

CARRERA DE MEDICINA VETERINARIA

TRABAJOS EXPERIMENTALES

Caracterización del perfil citológico de la mucosa vaginal durante el ciclo estral en perras con ayuda de inteligencia artificial.

**COELLO LUDEÑA MARIA ALEJANDRA
MEDICA VETERINARIA**

ZAPATA SAAVEDRA MATILDE LORENA

**MACHALA
2024**

CARACTERIZACIÓN DEL PERFIL CITOLÓGICO DE LA MUCOSA VAGINAL DURANTE EL CICLO ESTRAL EN PERRAS CON AYUDA DE INTELIGENCIA ARTIFICIAL

INFORME DE ORIGINALIDAD

4%

INDICE DE SIMILITUD

3%

FUENTES DE INTERNET

0%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Andrés Bello Trabajo del estudiante	1 %
2	Submitted to Universidad de Cantabria Trabajo del estudiante	<1 %
3	Submitted to Consorcio CIXUG Trabajo del estudiante	<1 %
4	www.slideshare.net Fuente de Internet	<1 %
5	es.scribd.com Fuente de Internet	<1 %
6	Submitted to Universidad Técnica de Machala Trabajo del estudiante	<1 %
7	atenos.com Fuente de Internet	<1 %
8	ai-paper-for.hatenablog.com Fuente de Internet	<1 %
9	www.codewithc.com Fuente de Internet	<1 %
10	analyticsindiamag.com Fuente de Internet	<1 %
11	www.researchgate.net Fuente de Internet	<1 %
12	Erick Molino-Minero-Re, José Gilberto Cardoso-Mohedano, Ana Carolina Ruiz-Fernández, Joan-Albert Sanchez-Cabeza. "Comparison of artificial neural networks and harmonic analysis for sea level forecasting"	<1 %

(Urias coastal lagoon, Mazatlan, Mexico)",
Ciencias Marinas, 2015

Publicación

13	es.slideshare.net Fuente de Internet	<1 %
14	genbiogan.wixsite.com Fuente de Internet	<1 %
15	revistas.udea.edu.co Fuente de Internet	<1 %
16	www.msmanuals.com Fuente de Internet	<1 %
17	lycoses.reverso.net Fuente de Internet	<1 %
18	www.flickr.com Fuente de Internet	<1 %
19	digibug.ugr.es Fuente de Internet	<1 %
20	idoc.pub Fuente de Internet	<1 %
21	issuu.com Fuente de Internet	<1 %
22	worldwidescience.org Fuente de Internet	<1 %
23	www.rcs.cic.ipn.mx Fuente de Internet	<1 %
24	www.repositorio.usac.edu.gt Fuente de Internet	<1 %
25	www.revele.com.ve Fuente de Internet	<1 %

Excluir citas

Apagado

Excluir coincidencias

Apagado

Excluir bibliografía

Apagado

CLÁUSULA DE CESIÓN DE DERECHO DE PUBLICACIÓN EN EL REPOSITORIO DIGITAL INSTITUCIONAL

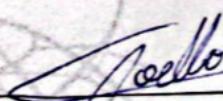
La que suscribe, COELLO LUDEÑA MARIA ALEJANDRA, en calidad de autora del siguiente trabajo escrito titulado Caracterización del perfil citológico de la mucosa vaginal durante el ciclo estral en perras con ayuda de inteligencia artificial., otorga a la Universidad Técnica de Machala, de forma gratuita y no exclusiva, los derechos de reproducción, distribución y comunicación pública de la obra, que constituye un trabajo de autoría propia, sobre la cual tiene potestad para otorgar los derechos contenidos en esta licencia.

La autora declara que el contenido que se publicará es de carácter académico y se enmarca en las disposiciones definidas por la Universidad Técnica de Machala.

Se autoriza a transformar la obra, únicamente cuando sea necesario, y a realizar las adaptaciones pertinentes para permitir su preservación, distribución y publicación en el Repositorio Digital Institucional de la Universidad Técnica de Machala.

La autora como garante de la autoría de la obra y en relación a la misma, declara que la universidad se encuentra libre de todo tipo de responsabilidad sobre el contenido de la obra y que asume la responsabilidad frente a cualquier reclamo o demanda por parte de terceros de manera exclusiva.

Aceptando esta licencia, se cede a la Universidad Técnica de Machala el derecho exclusivo de archivar, reproducir, convertir, comunicar y/o distribuir la obra mundialmente en formato electrónico y digital a través de su Repositorio Digital Institucional, siempre y cuando no se lo haga para obtener beneficio económico.



COELLO LUDEÑA MARIA ALEJANDRA

0705081974

DEDICATORIA

A mi bisabuela Zoila, que ni en su ausencia dejó de ser la luz de mi vida. Recuerdo con mucha nostalgia y amor todas esas tardes de risas en su casa, donde me sentía inmune a cualquier mal, porque no había lugar más seguro que un abrazo de ella.

A Gilberto, mi abuelo y mi segundo padre, quien desde la cuna me cuidó como su mayor tesoro. Mi abuela Maritza, la sonrisa que ilumina mis recuerdos, quien siempre estuvo para darme un abrazo o un consejo cuando más lo necesitaba.

A mis padres Antonio y Elizabeth por educarme con amor, paciencia y disciplina, por ser el impulso para lograr mis metas y por ser el apoyo incondicional en cada paso que doy.

A los amores de mi vida Annie y Beto, mis fieles compañeros, los amo con todo mi corazón y este logro es por y para ustedes.

AGRADECIMIENTOS

A Dios, por darme la sabiduría, perseverancia y serenidad para poder llegar lejos y para siempre hacer el bien. A mis padres que sin duda han sido un pilar fundamental en mi vida, les estoy eternamente agradecida por ser la fuerza que me mueve a seguir adelante. A mis abuelos, gracias por las buenas enseñanzas y por su amor. A mi tía Verónica, por ser mi amiga y soporte en los malos momentos.

A mi tutora y especialistas: Dra. Lorena Zapata, Dra. Ana Guerrero e Ing. Paola Gálvez expreso mi agradecimiento por su invaluable guía y orientación durante la realización de esta investigación, su conocimiento, paciencia y dedicación han sido fundamentales para el éxito de este trabajo. Al Dr. Lenin Aguilar, docente de la asignatura titulación II por su paciencia durante las últimas 16 semanas y por orientarnos a culminar con éxito nuestros trabajos experimentales.

A cada una de las personas que a lo largo de mi formación profesional me han brindado sus conocimientos desinteresadamente. A los docentes que me han sabido impartir sus materias desde el respeto y desde la experiencia, gracias.

A todas esas almas puras que se han sido parte de mi vida: Titi, Annie, Beto, Memo, Sophie, Pinky, Oreo, Negro, Rocko, Teo, Polly, Alejandrita, Blue, Pollo, Coco, Silvestre, gracias por enseñarme que una mirada agradecida vale más que mil palabras.

A Gabriela, gracias por ser mi compañera en las largas noches de redacción de este proyecto y por creer en mí y motivarme.

A mis buenos amigos, Brando, Dayanna, Cristhian, Milena, Josselyn y Nicolas, agradezco por su apoyo durante esta etapa, por las experiencias compartidas y su amistad.

RESUMEN

La caracterización del perfil citológico de la mucosa vaginal durante el ciclo estral en perras con Ayuda de Inteligencia Artificial" presenta un estudio cuyo objetivo principal es mejorar la precisión en la identificación de las diferentes fases del ciclo estral en perras mediante el uso de inteligencia artificial (IA). Este enfoque pretende superar las limitaciones de los métodos tradicionales de citología vaginal que, aunque efectivos, dependen en gran medida de la experiencia del clínico, lo que puede llevar a errores en el diagnóstico.

El estudio se enfoca en el desarrollo y aplicación de un modelo basado en IA, específicamente utilizando la técnica YOLOv8, para segmentar y clasificar las células de la mucosa vaginal en imágenes microscópicas. El modelo se entrenó y evaluó utilizando un conjunto de datos anotados, y sus resultados se compararon con los métodos tradicionales. Los resultados muestran que el modelo tiene un buen rendimiento en términos de precisión y eficiencia, lo que sugiere que la IA puede ser una herramienta útil en la práctica veterinaria para la citología vaginal.

Este trabajo concluye que la integración de IA en la medicina veterinaria no solo tiene el potencial de mejorar la precisión diagnóstica, sino que también podría facilitar la automatización de procesos clínicos, reduciendo la carga de trabajo de los profesionales y mejorando los resultados para los pacientes caninos.

ABSTRACT

Characterization of the cytological profile of the vaginal mucosa during the estrous cycle in bitches with the aid of Artificial Intelligence" presents a study whose main objective is to improve the accuracy in the identification of the different phases of the estrous cycle in bitches by using artificial intelligence (AI). This approach aims to overcome the limitations of traditional vaginal cytology methods that, although effective, rely heavily on the clinician's experience, which can lead to errors in diagnosis.

The study focuses on the development and application of an AI-based model, specifically using the YOLOv8 technique, to segment and classify vaginal mucosal cells in microscopic images. The model was trained and evaluated using an annotated dataset, and its results were compared with traditional methods. The results show that the model performs well in terms of accuracy and efficiency, suggesting that AI can be a useful tool in veterinary practice for vaginal cytology.

This paper concludes that the integration of AI in veterinary medicine not only has the potential to improve diagnostic accuracy, but could also facilitate the automation of clinical processes, reducing practitioner workload and improving outcomes for canine patients.

Índice de Contenido

I.	INTRODUCCION	10
II.	PLANTEAMIENTO DEL PROBLEMA	11
III.	JUSTIFICACIÓN	11
IV.	HIPÓTESIS.....	12
V.	OBJETIVOS.....	13
5.1.	Objetivo general	13
VI.	REVISIÓN BIBLIOGRAFICA	14
6.1.	Anatomía del sistema reproductivo	14
6.1.1.	Ovarios.....	14
6.1.2.	Trompas uterinas.....	14
6.1.3.	Vagina.....	15
6.1.4.	Vestíbulo y vulva.....	15
6.1.5.	Clítoris.....	15
6.2.	Fisiología reproductiva	16
6.2.1.	Ciclo estral	16
6.3.	Citología vaginal.....	22
6.3.1.	Toma de muestra	22
6.3.2.	Tinción Diff-Quik	23
6.4.	Clasificación de las células en la mucosa vaginal.....	25
6.4.2.	Intermedias	27
6.4.3.	Superficiales.....	27
6.4.4.	Anucleares.....	28
6.4.5.	Células en la fase del ciclo estral	29
6.5.	Inteligencia artificial	29
6.5.2.	Redes Neuronales Artificiales	31
6.5.3.	Aprendizaje automático (Machine Learning)	32
6.5.3.1.	Aprendizaje supervisado y no supervisado	33
6.5.4.	Análisis de imágenes con IA	33
6.5.5.	Lenguaje de programación Python	34
6.5.7.	YOLO V-8.....	36
6.5.8.	Comet	38
6.5.9.	Roboflow	39
6.5.10.	Data Augmentation	40
VII.	MATERIALES Y METODOS.....	42
7.1.	Tipo de estudio	42

7.2. Ubicación	42
7.4. Materiales y equipos	49
IX. CONCLUSIONES.....	65
X. RECOMENDACIONES.....	66
REFERENCIAS.....	67

Índice de ilustraciones

Ilustración 1 Técnica de toma de muestra	23
Ilustración 2 Células epiteliales de la mucosa vaginal.....	26
Ilustración 3 Célula Parabasal	26
Ilustración 4 Células parabasales.....	27
Ilustración 5 Células superficiales	28
Ilustración 6 Célula anuclear	29
Ilustración 7 Células etiquetadas con LabelMe	35
Ilustración 8 Comando LabelMe	35
Ilustración 9 Ubicación de la Facultad de Ciencias Agropecuarias.....	43
Ilustración 10 Data Set	45
Ilustración 11 Ejemplo del conjunto de datos generado.....	45
Ilustración 12 Gráfica de rastreo de los modelos.....	50
Ilustración 13 Gráfica de rastreo de los modelos	51
Ilustración 14 Gráfica general del rastreo de los modelos	51
Ilustración 15 Detalles del modelo	52
Ilustración 16 Matriz de confusión.....	54
Ilustración 17 Resultados de la detección de células	55
Ilustración 18 Resultados tomando una imagen como referencia	56
Ilustración 19 Logo de la aplicación.....	57
Ilustración 20 Ejemplo de resultados presentados por separado	58
Ilustración 21 Ejemplo de resultados presentados en una sola imagen	59
Ilustración 22 Toma de muestra.....	72
Ilustración 23 Toma de muestra.....	72
Ilustración 24 Observación de las muestras del microscopio.....	73
Ilustración 25 Toma de imágenes	73

Índice de tablas

Tabla 1 Modelos de YOLOv8	46
Tabla 2 Resumen del rendimiento del modelo de referencia (YOLOv8) en el conjunto de validación	55
Tabla 3 Funcionamiento de la aplicación CytoCells.....	61

I. INTRODUCCION

La citología vaginal es parte esencial de la práctica médica, es un método fácil y no invasivo para establecer en que etapa del ciclo estral están las hembras, además mediante este procedimiento se puede diagnosticar ciertas anomalías o patologías del aparato reproductivo. Es un método útil, debido a que los resultados son inmediatos y pueden ser utilizados en la consulta diaria por lo que el equipo necesario es limitado. Aunque es una técnica fiable, muchos clínicos no tan experimentados en el área pueden fallar, por lo que se necesita de una visión experta para dar un correcto diagnóstico e interpretación de los resultados (1). Por otra parte, el ciclo estral es un proceso recurrente que se produce a lo largo de la vida reproductiva de la hembra canina y que comprende una serie de cambios hormonales y fisiológicos en el sistema reproductivo (2). Este consta de las fases de proestro, estro y metaestro, y va precedido por la fase de anestro. (3)

La medicina veterinaria puede tener un notable avance si se incluye la inteligencia artificial (IA), debido a que los sistemas de IA podrían ayudar a los médicos a tener diagnósticos más precisos, dar tratamientos más adecuados, lo cual mejorará considerablemente la salud animal (4). La subjetividad y complejidad del análisis de imágenes en el ámbito de la medicina, tanto en humanos como en animales, ha llevado a los investigadores a adentrarse en el mundo de la IA y el deep learning, para automatizar este tedioso proceso. Pese que en la medicina humana esta más avanzada en esta área, la medicina veterinaria está empezando a hacer grandes avances (5). El potencial de la IA dentro del campo veterinario es ilimitado, se prevé un futuro prometedor donde la IA será una herramienta indispensable en la mayoría de las áreas veterinarias, desde el diagnóstico hasta el control epidemiológico (6). En cuanto a las aplicaciones móviles, se han desarrollado varias para ayudar a los veterinarios a tratar a sus pacientes de una manera más eficaz, a diario se crean nuevas aplicaciones destinadas a la medicina humana como también a la veterinaria, aunque la humana puede estar mucho más

avanzada, la veterinaria no se queda atrás. Dicho esto, es posible utilizar estas herramientas para aumentar la calidad de atención al paciente, así como también la calidad de los resultados diagnósticos (7).

II. PLANTEAMIENTO DEL PROBLEMA

El análisis citológico de la mucosa vaginal es una herramienta importante para el diagnóstico y manejo de la reproducción canina. Sin embargo, el análisis citológico tradicional requiere de un observador experimentado, lo que puede limitar su disponibilidad y confiabilidad.

Es de gran importancia el estudio del ciclo estral en perras, ya que podemos detectar ciertas anomalías reproductivas, como también diagnosticar patologías del sistema reproductivo, pero muchas veces los resultados dependen mucho de la experiencia del observador.

El observar una placa de citología vaginal y llegar a su interpretación toma aproximadamente unos 10 a 20 minutos, pero si son varias placas al día el cansancio visual puede surgir errores, por lo que aquí la inteligencia artificial juega un papel importante para precisar el diagnóstico y reconocimiento de las células, ya que existen patrones que son imperceptibles al ojo humano, lo que convertiría esta técnica en eficaz y precisa.

III. JUSTIFICACIÓN

La IA puede utilizarse para automatizar el análisis citológico de la mucosa vaginal en perras. Esto se puede lograr mediante el desarrollo de un modelo de IA que sea capaz de identificar los diferentes tipos de células presentes en la mucosa vaginal durante el ciclo estral.

El modelo de IA se puede entrenar utilizando un conjunto de datos de muestras citológicas de perras. El conjunto de datos debe incluir muestras de todas las fases del ciclo estral para que el modelo pueda aprender a identificar las diferencias entre las células de cada fase.

Una vez que el modelo de IA esté entrenado, se puede utilizar para analizar muestras citológicas de perras. El modelo puede proporcionar información sobre la fase del ciclo estral de la perra, así como sobre la presencia de posibles anomalías.

IV. HIPÓTESIS

La inteligencia artificial (IA) automatiza el análisis citológico de la mucosa vaginal en perras, mejorando la precisión y la eficiencia de este procedimiento.

V. OBJETIVOS

5.1. Objetivo general

Caracterizar del perfil citológico de la mucosa vaginal durante el ciclo estral en perras con ayuda de inteligencia artificial

Objetivos específicos

- Identificar las células presentes en la mucosa vaginal de las perras para determinar en qué etapa del ciclo estral se encuentran.
- Desarrollar un modelo de inteligencia artificial para automatizar el proceso de análisis de las muestras citológicas de la mucosa vaginal.
- Crear una aplicación móvil que ayude a los médicos veterinarios a caracterizar el perfil citológico de la mucosa vaginal.

VI. REVISIÓN BIBLIOGRAFICA

6.1. Anatomía del sistema reproductivo

La hembra y su sistema reproductivo tienen funciones reproductivas, que incluyen la producción de ovocitos, brindar un entorno para el desarrollo y nutrición del feto, la parición y luego continuar con la etapa de lactancia (8). Los órganos reproductivos femeninos se componen de ovarios, trompas uterinas, vagina, vestíbulo, vulva y clítoris (9).

6.1.1. Ovarios

Los ovarios o también llamados gónadas femeninas, son un par de órganos ovalados, unidos por un mesovario a la pared de la cavidad y también por el mesosalpinx, se encuentran ubicados caudales al riñón. Tiene un aspecto liso antes del celo, en cambio en perras multiparas puede tener una superficie rugosa o nodular. En algunos casos los ovarios tienen diferentes tamaños, siendo así, el izquierdo suele ser el más grande (9). Su función es producir óvulos y hormonas sexuales tales como el estrógeno y progesterona. El estrógeno es fundamental para el crecimiento de los óvulos y la progesterona que acondiciona el útero para la gestación. Una vez que ya se ha alcanzado la pubertad y aparece el primer ciclo estral, el tamaño y forma de los ovarios cambian (10).

6.1.2. Trompas uterinas

Las trompas uterinas son estructuras angostas y enrevesadas ubicadas cerca de los ovarios. Está rodeada por procesos similares a dedos conocido como fimbrias, que se expanden por las superficies de los ovarios para atrapar los óvulos cuando se liberan. Están suspendidas por una parte del peritoneo visceral conocido como mesosálpinx, que es luego se continua con el mesovario y mesometrio (11).

Miden alrededor de 5 a 10 cm de longitud y pocos milímetros de ancho. Se proyecta parcialmente hacia afuera en el ostium de la bursa ovárica, la porción final de la trompa ovárica,

también conocida como istmo, se puede reconocer externamente, pero la porción media suele estar cubierta por tejido adiposo (12).

6.1.3. Vagina

Es un tubo relativamente largo, sus paredes son delgadas y elásticas a lo largo y ancho. Está localizada en una ubicación media, en el interior de la cavidad pelviana, posicionada dorsalmente con el recto y la vejiga, mientras que ventralmente con la uretra. Consta de dos partes, las cuales forman el órgano reproductor femenino y como también el conducto de parto: la parte craneal del conducto es exclusivamente reproductivo que se extiende desde el cuello uterino hasta la uretra. La parte caudal o también llamado vestíbulo, cumple doble función: urinaria y reproductiva (13).

6.1.4. Vestíbulo y vulva

El vestíbulo es significativamente más pequeño que la vagina, ubicado casi en su totalidad, caudal al arco isquiático, lo que le permite direccionarse ventralmente hasta su abertura en la vulva. Las paredes del vestíbulo tienen menor elasticidad comparadas con las paredes de la vagina, son muy vascularizadas, con un paquete de venas que constituyen un parche de tejido eréctil denominado bulbo vestibular. Esta estructura se une con el exterior por medio de la vulva, cuyos límites están determinados por la unión de los labios en sus comisuras dorsal y ventral (13).

6.1.5. Clítoris

Es un homólogo femenino del pene, se encuentra en una parte de la región anterior de la vulva. El clítoris, es formado por tejido muscular, fibroso y adiposo, tiene una red repleta de vasos sanguíneos y linfáticos. El epitelio que lo recubre es el escamoso no queratinizado. En las perras, representa una estructura aproximadamente grande, la cual se compone de tres partes: la crura, el cuerpo y el glande (14)

- **Crura:** Se despliega en una forma de abanico para sujetar las estructuras exteriores del clítoris y se une a los tejidos subyacentes. A partir de aquí se extiende el cuerpo.
- **Cuerpo:** La zona cilíndrica más importante del clítoris, consta de dos finas columnas de tejido eréctil o cuerpos cavernosos.
- **Glande:** Forma el extremo del clítoris, aunque está bastante desarrollado, no es fácil de visualizar cuando no está erecto (14).

6.2. Fisiología reproductiva

Los ciclos reproductivos de los animales domésticos, tienen periodos de receptibilidad sexual o estró limitados, por lo que el término ciclo estral es el correcto (15). La perra es una hembra que se caracteriza por ser monoestrica, con una o dos ovulaciones anuales en lapsos de 5 a 12 meses, aunque su actividad reproductiva no tiene un patrón predeterminado. En el ciclo sexual de las perras, se puede distinguir algunos aspectos diferentes a las demás especies domésticas, entre algunas sobresalen los largos periodos de receptividad, actividad luteal (diestro) e inactividad sexual (anestro). La hembra canina alcanza la pubertad dentro de los 6 y 24 meses, cabe recalcar que las pequeñas razas suelen ser más prematuras que las grandes y entre el tercer y cuarto estró se logra alcanzar el potencial reproductivo (16).

Durante el primer celo, se puede ver el llamado “celo partido” que consiste en una fase inicial de inflamación y edema de la vulva con liberación de líquido serosanguinolento, rechazo a la monta, continuando con una segunda fase en el curso de 1 a 3 semanas en el que se puede ver que los signos externos desaparecen y comienza la ovulación (16).

6.2.1. Ciclo estral

El ciclo estral consta de cuatro fases: la primera fase denominada como anestro o de inactividad sexual que dura en promedio cuatro meses. Se continúa con el proestro, que se lleva a cabo en un periodo de aproximadamente nueve días y hay una notable tumefacción vulvar acompañada

de sangrado. Luego se da la tercera fase, cuando la hembra finalmente acepta al macho y ocurre la ovulación espontánea que tiene una duración de alrededor de nueve días. En caso de que no se presente la preñez, aparece la tercera fase que se conoce como diestro, dura aproximadamente 65 días y termina en un período de inactividad sexual, mejor conocida como el anestro (17).

En las perras, la finalización del anestro, el inicio del proestro, incremento de la secreción de estradiol folicular y crecimiento de los folículos aptos para ovular, se dan por el aumento de la GnRH (18).

6.2.1.1. Hormonas sexuales del ciclo estral

En la adenohipófisis se da la producción de tres hormonas fundamentales en la reproducción de la hembra canina que son: la Hormona Foliculoestimulante (FSH), la Hormona Luteinizante (LH) y la Prolactina (PRL). La FSH tiene como propósito inducir la formación de folículos estrales. El desarrollo del cuerpo lúteo es el resultado de la acción de la LH que es primordial en el proceso ovulatorio y para luteinizar la granulosa. Mientras que la PRL se encarga del desarrollo del tejido que servirá para que secrete la glándula mamaria y que la lactación sea preservada, como también actúa como una hormona luteotrófica (19).

La Hormona liberadora de Gonadotropinas (GnRH) es la encargada de controlar la secreción de FSH y LH. Cuando los valores de estrógenos aumentan, igualmente lo hace la sensibilidad a la GnRH, lo que ocasiona que se liberen las gonadotropinas, a diferencia de la progesterona que tiene un efecto opuesto (19).

Hay una respuesta positiva a causa del b-estradiol y consiguiente se da la liberación de gonadotropinas, como consecuencia del incremento progresivo de los niveles de estrógenos. En contraste, la respuesta negativa necesita de niveles de estrógenos basales o mínimos con una duración corta (19).

Los folículos ováricos y su síntesis de folículos ováricos son controlada por la FSH, al igual que actúa sobre las células de la granulosa. La producción de testosterona es controlada por la síntesis de estrógenos donde actúa la LH (19)

6.2.1.2.Fases del ciclo estral

6.2.1.2.1. Proestro

En esta fase se da el crecimiento folicular, dura entre siete a nueve días, aunque puede variar mucho de una perra a otra. En el transcurso de este periodo, el macho es atraído por la hembra, el cual intentara montarla y servirla, pero ella rechazara el apareamiento. El estrógeno es la hormona predominante en esta fase, sus niveles elevados provocan:

- Producción de feromonas que atraen a los machos
- En el útero se producen numerosos capilares y se da una filtración de sangre al lumen uterino, lo que produce un flujo vaginal serosanguinolento
- Edema de los labios vulvares e hinchazón de la región perineal, por lo que la vulva se agranda y sobresale.
- Inflamación edematosa de la pared vaginal, por lo que el revestimiento de la vagina se hincha y se ve brillante
- Incremento del número de capas de células de revestimiento epitelial de la vagina
- Una respuesta negativa sobre el hipotálamo y la hipófisis para inhibir la producción de FSH

Al mismo tiempo que los folículos maduran, el proestro se transforma en celo verdadero o estro (20).

Cuando el proestro está llegando a su fin, los niveles de estrógeno comienzan a disminuir una vez que los folículos han llegado a su madurez y empieza la luteinización de los folículos principales, lo que causa un aumento lento de los niveles de progesterona antes de la ovulación.

El incremento inicial de la progesterona es lento (0,4-0,8ng/ml) y se duplican los valores basales, que suele pasar contemporáneamente con el aumento preovulatorio de LH (1,0-3,0ng/ml) (21).

6.2.1.2.2. Estro

Puede tener una duración variable, pero el promedio es de 7 a 9 días. Los niveles de estrógenos llegan al máximo y provocan una mayor segregación de LH por medio de la apófisis anterior, por ende, aquí el estrógeno tiene una respuesta positiva sobre la apófisis anterior (20). El aumento de la LH ocurre luego de que los folículos preovulatorios y se produce un cambio abrupto en los niveles de estrógenos y progesterona, este cambio es lo que desencadena los síntomas de receptibilidad de la hembra hacia el macho (21). Los folículos empiezan a madurar y se da una luteinización preovulatoria (22).

El estro se caracteriza por que la hembra acepta al macho, con presencia de respuestas postulares específicas y da paso para que se dé el servicio, aquí es cuando el periodo de estro empieza. Este lapso receptivo normalmente coincide con la onda de LH, aunque en ocasiones puede darse entre 1 a 4 días después o como también nunca producirse. La vulva aún sigue con su tamaño aumentado, sin embargo, el edema disminuye haciendo que este más flácida a diferencia de la fase anterior, esto para facilitar la penetración del macho. También el flujo vulvar se reduce y es menos sanguinolento que en el proestro, por lo que la coloración cambia a un color más claro, a pesar de que algunas hembras pueden tener un flujo sin variaciones de color entre las dos fases (22).

6.2.1.2.3. Diestro o metaestro

Es la fase donde comienza la secreción de la progesterona desde la formación de los cuerpos lúteos. Comienza en el instante que la hembra manifiesta una conducta de rechazo por la copula, la duración de este periodo es variable, alrededor de unos 60 a 80 días. Una de las

características principales es el cambio en el tamaño y tono de la vulva, también pierden el interés antes mostrado por el macho (23).

La hormona más importante en esta fase es la prolactina, que es la hormona luteotrópica, ya sea en perras gestantes o no gestantes, por lo cual el cuerpo lúteo necesita de la prolactina para liberar cantidades normales de progesterona. Se producen cambios considerables en el útero que hacen a la hembra capaz de apta para mantener la gestación. Todas las perras, a pesar de no estar gestantes tienen cuerpos lúteos funcionales, lo que produce que esta fase se prolongue por 10 a 20 días más que en la perra gestante, por lo que la fase luteal en las no gestantes tiende a decaer lentamente. El deterioro del cuerpo lúteo y la suspensión de secreción de progesterona se puede considerar que es el final del diestro y el útero entra en una etapa de reparación, donde se requiere de 1 a 3 meses y se considera que tal vez sea uno de los agentes causales de los intervalos interstrales prolongados. En el diestro se da una secreción de FSH Y LH que se considera como episódica (24).

Los niveles de progesterona elevados son responsables de iniciar el crecimiento glandular en el tejido mamario, el cual una vez que la prolactinemia incrementa al final de la gestación (1 a 3 semanas), es más notorio, lo que da inicio también a la lactación. El estradiol entra también en esta fase, estimulando el crecimiento mamario y puede tener parte en la dilatación del cuello uterino. Durante la preñez los niveles de LH son bajos, también la duración del diestro es de aproximadamente de 56 a 58 días (24).

6.2.1.2.4. Anestro

La fase de anestro es el tiempo que transcurre entre el parto y el comienzo del proestro, es decir entre el periodo luteal y la aparición de la siguiente fase folicular. De la misma manera que las demás fases del ciclo estral, la duración es variable, pero suele darse en 4,5 aproximadamente (24).

En las perras involucra la ausencia de actividad ovárica, tiene una duración de mínimo siete semanas luego de que los valores de los niveles de progesterona disminuyan a menos de 1-2 ng/ml. El estradiol sérico varía pero la mayoría de las veces es bajo (5-10 pg/ml). La LH basal es baja (<1-2 ng/ml) entre pulsos ocasionales, de altura variable y a menudo grandes (3-30 ng/ml) en lapsos de 7-18 h o más. La FSH se eleva (50-400 ng/ml, media 140), mientras que la progesterona sérica mantiene sus niveles por debajo de 1 ng/ml, con un nivel aproximado a 400 pg/ml a los 30 a 40 días previos al estro (25).

En el final del anestro, nuevos folículos en el ovario empiezan a aparecer nuevos folículos en el ovario y hay secreción de estrógenos. Una vez que los niveles en sangre han incrementado lo suficiente, empiezan a notarse externamente los signos del proestro, dando inicio nuevamente al ciclo (26).

6.2.1.3. Cambios en el aparato reproductor a durante el ciclo estral

En los órganos reproductivos de la hembra canina se producen una serie de cambios a consecuencia de las hormonas sexuales secretadas en este periodo (27).

Útero: El endometrio se engrosa, se torna más glandular y mucoide, esto por el resultado de la progesterona. A medida que se da la segregación de progesterona, el efecto sigue preparándose para recibir a los óvulos fecundados (27).

Vagina: Hay un cambio en el epitelio de revestimiento, esto es influenciado por los estrógenos acompañado por la progesterona (27).

Glándulas mamarias: Su tamaño incrementa ligeramente por la progesterona (27).

6.3.Citología vaginal

La citología vaginal es primordial para el seguimiento de la reproducción, este método es sencillo, barato e invasivo para el animal. El objetivo principal de esta técnica es distinguir en que etapa del ciclo estral esta la hembra (28).

Cuando la citología vaginal se complementa con la historia clínica, el examen físico y otros métodos diagnósticos, aumenta las posibilidades de realizar un mejor diagnóstico y poder dar un tratamiento apropiado a patologías o enfermedades del tracto genitourinario (29).

Esta técnica le permite al veterinario, establecer si la hembra está realmente en celo, decidir cuando es el instante propicio para realizar pruebas de progesterona y LH que den con exactitud el momento de la ovulación, determinar si se ha pasado el tiempo en el ciclo estral para llevar a cabo la inseminación artificial en perras que no son receptivas para la monta natural, identificar si la hembra está bajo los efectos de estrógenos ya sean exógenos o endógenos, estimar el día indicado para realizar una cesárea programada (30), dado que la morfología de las células se refleja a consecuencia de los cambios hormonales que se dan en la vagina en el transcurso del ciclo estral. (31)

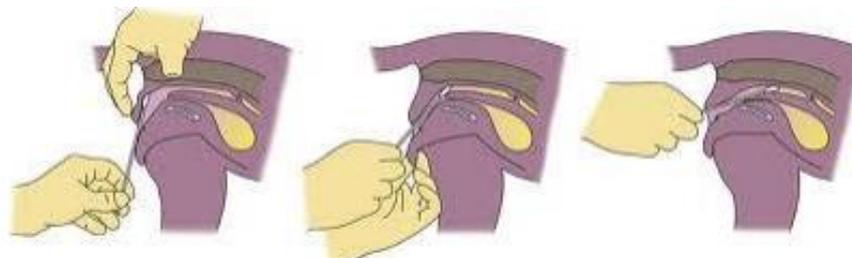
6.3.1. Toma de muestra

En la toma de muestra, preparación y tinción de un frotis de citología vaginal, no se requieren de muchas habilidades y es un método que se puede realizar de forma ágil y es poco costoso. sin embargo, la interpretación y análisis de las muestras pueden en ocasiones verse afectados por diversos factores, ya que los diferentes tipos de muestreo y técnicas de tinción pueden influir en los resultados al momento de hacer la evaluación, también la habilidad del observador y el cambio entre las distintas fases de los estadios celulares a lo largo de ciclo estral y las características que puedan presentar cada caso. (32)

Para realizar la toma de muestra, se debe como primer paso limpiar la vulva, luego se utiliza un hisopo estéril, este se introduce por la unión dorsal de los labios vulvares, avanzando con delicadeza hasta poder pasar la unión vestíbulo vaginal, para alcanzar la porción caudal de la vagina, donde se hacen movimientos circulares con la finalidad de recolectar material celular (19).

Se pasa el hisopo varias veces por un portaobjetos de vidrio (asegurarse de que este limpio), tener en cuenta de no presionar el hisopo contra el portaobjetos para no romper las células (33). La Muestra se fija en alcohol al 95% por 5 a 10 minutos y luego se tiñe la placa para observar en el microscopio. Para la tinción de las muestras se puede usar varios métodos como el Papanicolau, Giemsa, Shorr, Wright y Diff-Quik (19).

Ilustración 1 Técnica de toma de muestra



Fuente: Universidad Técnica del Litoral

En la coloración de los extendidos vaginales, se pueden usar varias tinciones, por lo general se eligen las que requieran menos tiempo y menos complejidad para ser utilizadas dentro del consultorio, por otro lado, las técnicas más complicadas serán usadas dentro de un laboratorio. Las diferencias morfológicas tienen que ser reconocibles con cualquier tinción antes mencionadas (34)

6.3.2. Tinción Diff-Quik

Se desarrolló por primera vez en 1970 por Bernard Witlin, es una tinción de tipo Romanovsky, se considera que es panóptica, lo que significa que es para tener una mejor capacidad visual,

con la que se puede distinguir áreas basófilas y acidófilas. Es posible caracterizar una cantidad variada de frotis, como los de sangre, pero no los de aspiración con aguja fina. Según la cantidad de veces que la placa sea sumergida, se dará el grado de sombreado e intensidad de la tinción (35).

Es la tinción que se usa con más frecuencia, entre sus mayores ventajas es que la fijación del frotis se da solamente al aire libre, la tinción toma unos 45 segundos como máximo. Esta técnica permite analizar con mayor facilidad las características de las células (36).

Consta de tres reactivos que permiten la coloración rápida de las muestras para su estudio morfológico: la primera es la solución fijadora que tiene verde sólido (0.002 g/l) en metanol, continuando con la solución tinción I (colorante ácido) que su contenido es de eosina (1.22 g/l) en un tapón de fosfato, solución azul, Ph 6.6 y como conservante ácido de sodio al 0.1% (w/v) y como ultimo esta la solución de tinción II (colorante básico) que contiene tinción de Tiazina (1.1 g/l), tapón de fosfato de pH 6.6 (35).

Entre sus aplicaciones esta:

- Frotis sanguíneo
- Frotis de medula ósea
- Parasitología
- Micología
- Histo-citología
- Para la morfología de semen
- Citología de líquidos biológicos (35)

6.3.2.1. Proceso de tinción con Diff-Quik

1. Colocar en tres recipientes para tinción los tres reactivos en el siguiente orden:

- a) Solución fijadora

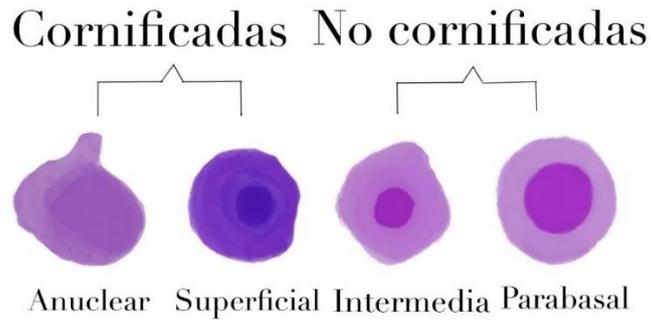
- b) Colorante ácido
 - c) Colorante básico (35)
2. El frotis es fijado con la solución fijadora.
 3. El portaobjetos se debe sumergir y sacar de 5 a 10 veces en el colorante rojo o solución eosinofílica.
 4. El portaobjetos se debe sumergir y sacar de 5 a 10 veces en el azul o solución basofílica.
 5. Se enjuaga la placa con agua de grifo.
 6. Se deja secar y como algo optativo se puede colocar un cubreobjetos (37).

6.4. Clasificación de las células en la mucosa vaginal.

La actividad ovárica durante el proestro, aumentan el nivel de estrógeno sérico, lo que genera un conjunto de cambios en el epitelio y mucosa vaginal. Se engrosa el epitelio vaginal y se aumenta las capas celulares a causa de los estrógenos. En el transcurso de este proceso, se da una separación de la membrana basal, la cual se dirige hacia el lumen vaginal, lo que provoca la muerte celular, ya que se alejan del soporte vascular nutricio. En cuanto se da la muerte de las células vaginales esféricas, comienzan a aumentar de tamaño y se tornan irregulares, los núcleos también se modifican disminuyendo su tamaño, presentan picnosis y finalmente se destruyen que se da como resultado una célula enucleada (38).

Se pueden encontrar cuatro tipos de células presentes en la mucosa vaginal: parabasales, intermedias, superficiales y anucleares. Se considera que las células están asociadas a las fases del ciclo estral (39).

Ilustración 2 Células epiteliales de la mucosa vaginal



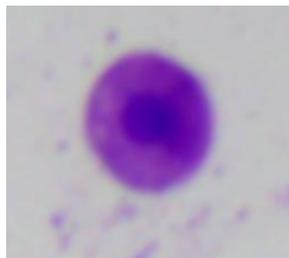
Fuente: Autor

En los frotis, además se pueden encontrar otras células como glóbulos rojos, leucocitos, bacterias, células tumorales, células epiteliales de la fosa del clítoris, células trofoblásticas gigantes y restos. (40)

6.4.1. Parabasales

Células epiteliales, de poco tamaño, basófilas, redondas u ovaladas, su núcleo es grande. Son bastante comunes en hembras que no alcanzan aun su pubertad, casi no se presentan en las demás edades, a menos que sea durante el diestro, anestro o un proestro precoz (28). Son las más pequeñas en la observación de una muestra vaginal (41).

Ilustración 3 Célula Parabasal



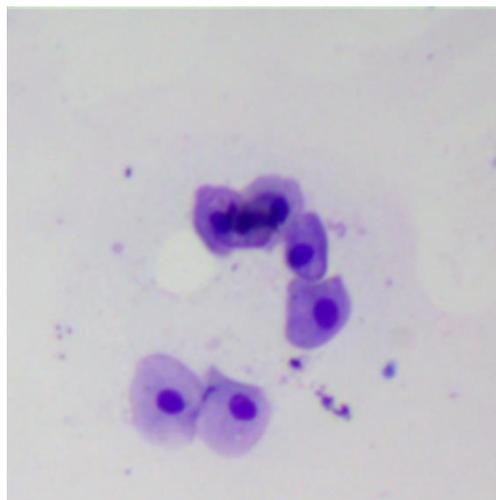
Fuente: Autor

Algunas veces las células parabasales pueden presentar granulocitos neutrófilos en su citoplasma, por esto se las denomina células metastáticas, no obstante, también pueden encontrarse en otras etapas del ciclo estral o cuando hay un cuadro de vaginitis. (40)

6.4.2. Intermedias

Su tamaño es variable, logrando clasificarlas en células intermedias pequeñas y grandes. Normalmente son grandes, de bordes irregulares y a pesar de que los núcleos de estas células pequeñas y grandes son casi iguales en magnitud que los de las células parabasales que son un poco más grandes y con presencia de mayor citoplasma. La aparición de esta célula marca la fase antes de que se transforme en una superficial, que destaca durante el proestro (42). Perduran durante todas las fases del ciclo estral excepción del estro. Su citoplasma toma una coloración azul grisáceo pálido, la queratinización temprana hace que tenga leves irregularidades, lo que se va haciendo más notable mientras el ciclo estral va a empezar (41).

Ilustración 4 Células parabasales

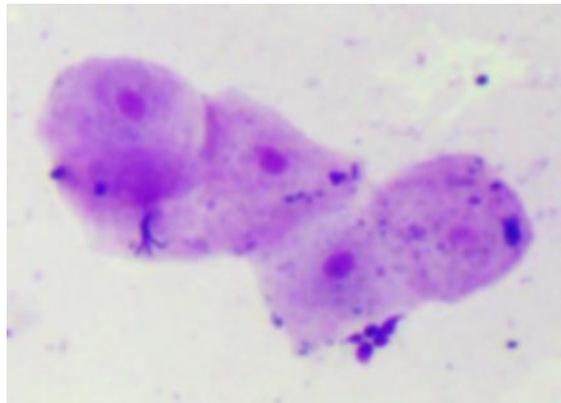


Fuente: Autor

6.4.3. Superficiales

En la observación de la citología, son las células con mayor tamaño, con bordes irregulares, núcleo pequeño, con presencia de picnosis, aunque a veces no presentan uno. Se ubican en la capa celular próxima al lumen vaginal, manifiestan los cambios particulares de la muerte celular (34).

Ilustración 5 Células superficiales

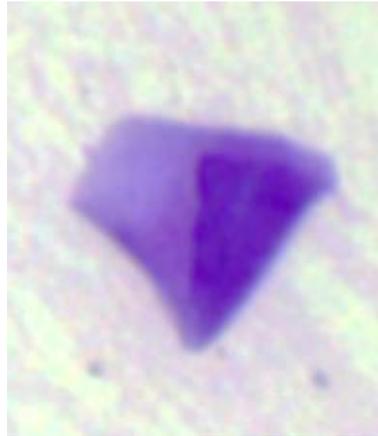


Fuente: Autor

6.4.4. Anucleares

Célula de gran tamaño, no presenta núcleo con bordes angulosos o irregulares, habitualmente predominan en el estro (41). Son células superficiales grandes cornificadas que sufren un deterioro para transformarse en células anucleadas muertas. Mientras el celo está presente, habitualmente se tiñen de azul (39).

Ilustración 6 Célula anuclear



Fuente: Autor

6.4.5. Células en la fase del ciclo estral

- **Anestro:** Poca presencia de células y se puede encontrar en su mayoría células parabasales (43).
- **Proestro tardío:** Aquí principalmente se encuentran células intermedias, se pueden observar una cantidad mínima de células superficiales, glóbulos rojos y bacterias (43)..
- **Estro:** En esta fase destacan las células epiteliales superficiales, no es visible la presencia significativa de bacterias (43).
- **Diestro temprano:** Presencia de células epiteliales intermedias pequeñas y parabasales, bacterias y neutrófilos (43).

6.5. Inteligencia artificial

La Inteligencia Artificial es la capacidad que tiene un programa informático o una máquina para pensar y aprender de forma parecida a como lo hace un ser humano, tratando de ser lo más cognitivo posible por medio de su sistema de Redes Neuronales Artificiales (RNA) (44). Los algoritmos de la IA comprenden desde el aprendizaje, la percepción, solución de problemas hasta el entendimiento de lenguaje y/o razonamiento lógico (45).

El termino Inteligencia Artificial fue acuñado por primera vez en 1956 por John McCarthy en una conferencia celebrada sobre el tema. En la actualidad, la IA está presente en nuestro día a día de multiples formas, desde juegos hasta la aviación (46).

6.5.1. Aplicaciones de la Inteligencia artificial en Medicina Veterinaria

La IA en veterinaria tiene un sinnúmero de aplicaciones en varios aspectos de la práctica veterinaria, entre ellos el diagnóstico, consultas, salud pública, agricultura, investigación, la educación y la industria (6).

La mayoría se los trabajos publicados sobre veterinaria e IA se basan en el estudio y análisis de imágenes médicas. La primera publicación que se utiliza la expresión de aprendizaje automático en medicina veterinaria fue la de McEvoy y Amigo en 2013, que desarrollaron una red neuronal para clasificar característica de imágenes de radiografías pélvicas. Con la aparición de las redes neuronales se ha explorado su uso para diagnosticar y detectar enfermedades y patologías por medio de imágenes clínicas con ayuda de radiografías torácicas y de tomografías computarizadas caninas, radiografías felinas, imágenes de resonancias magnéticas caninas, imágenes de ecografías caninas e imágenes de pezones de vacas lecheras (47).

Se debe tener conciencia que la IA ha sido de gran ayuda dentro de algunas áreas en la medicina veterinaria. En epidemiología y salud pública ha sido útil como una poderosa herramienta para recolectar y analizar grandes cantidades de información, a realizar tareas de vigilancia epidemiológica y predecir un brote de alguna enfermedad. También ha sido aplicada en la producción para detectar enfermedades, gestión ambiental, evaluación del crecimiento, para puntuar los pezones, detectar cojera en vacas lecheras, predecir el parto según su comportamiento y evaluar la calidad de la carne (48).

6.5.2. Redes Neuronales Artificiales

Las redes neuronales artificiales (RNA), surgieron en el año 1943 y son una clase de modelo matemático usado en el aprendizaje automático que está inspirado por el sistema nervioso humano, por lo general es son vinculadas con el aprendizaje supervisado. Están formadas por dos elementos principales: la arquitectura y los pesos. La arquitectura se compone de nodos o neuronas que son las unidades básicas de las RNA. Se dispone en capas de nodos verticales, están unidas por conexiones, de esta manera cada nodo tiene conexión con todos los demás nodos en la capa siguiente. La primera capa es la de entrada, la cual recibe los datos para analizar, la última es la de salida y entre estas dos capas hay unas ocultas que se conocen como ocultas ya que tanto el usuario como el software no tiene acceso a los datos calculados en estas. En las capas ocultas, cada nodo es capaz de aprender una característica distinta, como, por ejemplo: curvas, líneas o brillo en una imagen en específico (5).

Los pesos son números, generalmente designados aleatoriamente, que son multiplicado por cada nodo que se acoplan en el proceso de entrenamiento de la red, su objetivo es probar la fuerza de la influencia de un nodo en los nodos vecinos, a continuación, la información atraviesa por una función de activación y al final todos los datos se mezclan para determinar la salida final de los datos (5).

Para decisiones complejas se requiere de redes neuronales de múltiples capas ocultas y estas dan lugar a redes neuronales profundas, por lo tanto, modelos de aprendizaje profundo. Las características que cada capa aprende no son establecidas por un ingeniero humano, sino por el modelo, lo único que se tiene que programar son la capa de entrada, el número de capas ocultas, la cantidad de nodos en cada capa oculta y el número de repeticiones en el entrenamiento (5).

6.5.3. Aprendizaje automático (Machine Learning)

Es un subcampo dentro de la inteligencia artificial, donde un ordenador genera sus propios criterios para la toma de decisiones a base del análisis de datos, mas no en una programación pre establecida. Sus características principales son la capacidad de automatizar tareas repetitivas y laboriosas, analizar conjuntos de datos de gran magnitud que resultan complejos para detectar patrones, dar pronósticos a futuro o adaptar dinámicamente la toma de decisiones. La capacidad del aprendizaje automático para analizar y extraer información de los grandes conjuntos de datos numéricos y visuales de varios formatos que se generan en el diagnóstico por imagen, así como también para lograr imitar el proceso de evaluación de imágenes realizado por los humanos (48).

El Machine Learning referencia a un grupo de metodologías que facilitan a los ordenadores “aprender” la relación entre las variaciones numéricas de los datos y ciertos valores objetivo. Se han utilizado en diferentes aplicaciones los métodos de aprendizaje como la máquina de vectores de soporte, entropía máxima, bosque aleatorio y la red neuronal artificial (49).

Un ejemplo común de aprendizaje automático en la comunidad médica del diagnóstico por imagen es la radiómica. La radiómica es lo que se conoce como el análisis cuantitativo de la intensidad de los píxeles o vóxeles. El concepto del aprendizaje automático aplicado en radiómica es que las características se pueden obtener de una determinada zona de interés dentro de una imagen y una serie de subconjuntos de características se pueden usar para el modelado. Este análisis radiómico de imágenes ofrece una recopilación coherente, reproducible e interpretable de rasgos de una imagen, por lo tanto, se puede analizar ya sea con aprendizaje supervisado o no supervisado (50).

6.5.3.1. Aprendizaje supervisado y no supervisado

Los tipos de aprendizaje automático más importantes son: supervisado y no supervisado. En el no supervisado, la información no está etiquetada, solo es presentada en el ordenador como datos de entrada y la inteligencia artificial aprende patrones para determinar su salida, sin embargo, con este tipo de aprendizaje no se consiguen buenos resultados, ya que como utiliza técnicas como el clustering para poder clasificar los patrones semejantes en imágenes, lo que lo hace impredecible porque no recibe una guía de patrones para el desarrollo de aprendizaje. Por otro lado, el aprendizaje supervisado, se proporciona datos ya etiquetados por personas expertas en este campo, estos son conocidos como datos reales para poder entrenar el modelo, el ordenador luego aprende una función matemática que establece entradas y salidas en función a los pares de datos que se le proporciona (5).

En el campo de la medicina y el diagnóstico por imagen, el tipo de aprendizaje más usado es el supervisado, aquí se incluye un clásico modelo de aprendizaje que son las redes neuronales artificiales, como demostración de los fundamentos del aprendizaje automático (5).

6.5.4. Análisis de imágenes con IA

Desde la aparición de la patología digital, la IA ha sido progresivamente utilizada para el análisis de tejidos en imágenes, así como para la observación y almacenamiento de imágenes citológicas. Clínicamente, se ha aplicado en caballos con cólico para saber si se necesita cirugía y si habrá riesgo de muerte o no, utilizando la historia clínica, con una exactitud del 76% al 85% (48).

Al hablar de diagnóstico por imagen con IA, podemos decir que esta se enfoca en la detección, segmentación o clasificación de las características de una imagen. En la detección se pueden encontrar anomalías, en la segmentación se puede delimitar estructuras en una imagen, en la clasificación se asigna una categoría a la imagen (48).

En la actualidad, se conocen pocos sistemas de IA para diagnóstico veterinario por imagen disponibles en el mercado, no obstante, estos programas no se han sometido a revisiones por expertos, las que han sido revisadas hasta ahora, se enfocan en pruebas de concepto para demostrar que la IA puede detectar con precisión anomalías en el tórax canino (48).

6.5.5. Lenguaje de programación Python

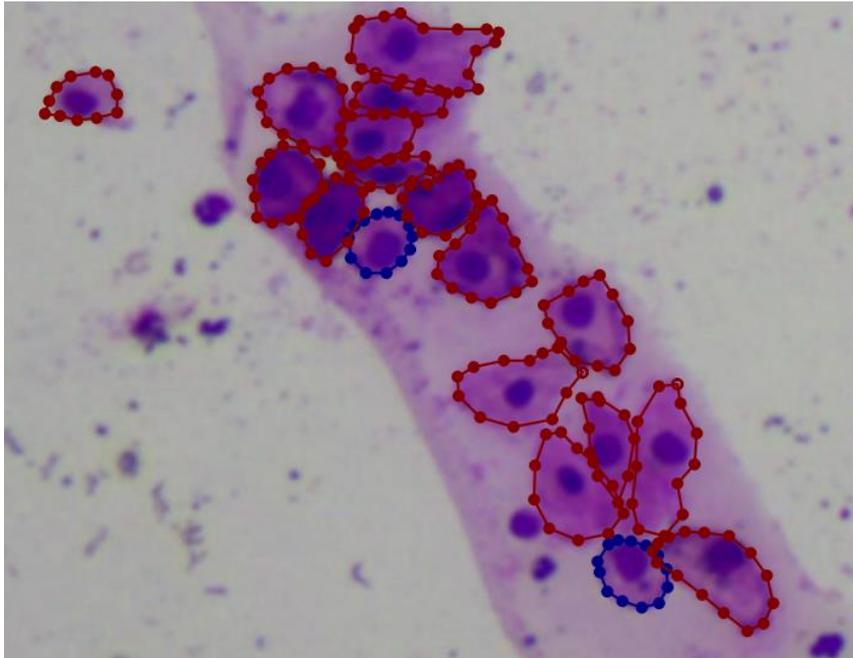
Python se lo conoce como un lenguaje de programación orientado a objetos, fue creado en 1989 por Guido Rossum. Es idóneo para el desarrollo rápido de prototipos de aplicaciones complejas. Es utilizado dentro de grandes empresas, como la NASA, Google, YouTube, BitTorrent, etc. (51).

Tiene una filosofía de diseño que hace hincapié en la lectura del código, haciendo uso de espacios en blanco significativos. Python es simple y fácil de aprender, cuenta con un sistema de tipos dinámicos y gestión automática de memoria, es capaz de ser compatible con varios paradigmas de programación, como la programación orientada a objetos, imperativa, funcional y procedimental y dispone de una amplia biblioteca estándar. Puesto que no hay compilación, el proceso de edición-prueba-depuración es bastante rápido, para depurar un programa Python es bastante fácil (52).

6.5.5.1. LabelMe

Es herramienta utilizada para la anotación de imágenes de código abierto que funciona con Python, que fue inspirada en una herramienta de anotación web del MIT con el mismo nombre. Posibilita hacer anotaciones para detección, clasificación y segmentación de objetos dentro de un conjunto de datos de visión por ordenador, Se puede hacer anotaciones dibujando polígonos, rectángulos, círculos, líneas y puntos. (53)

Ilustración 7 Células etiquetadas con LabelMe

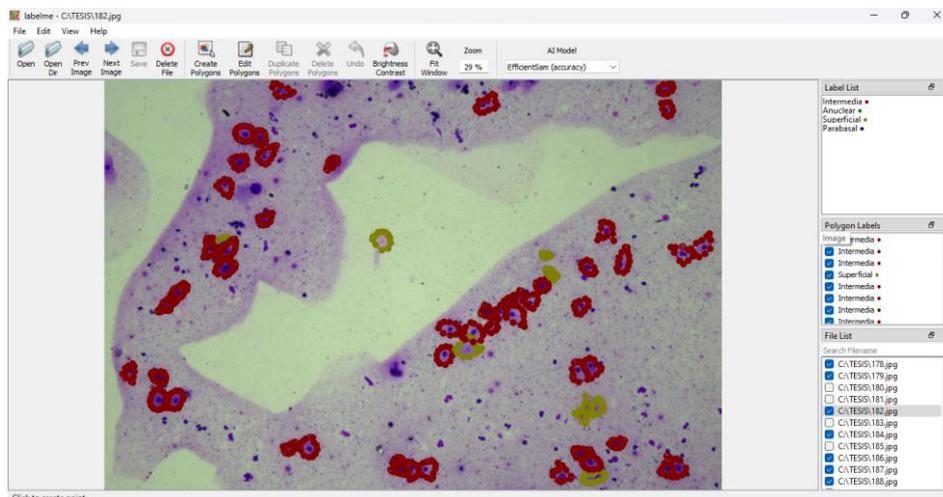


Fuente: Autor

Fue diseñado con el fin de reconocer objetos en contraposición al reconocimiento de instancias, para lograr el reconocimiento una clase de objetos, es necesario múltiples imágenes de diferentes instancias de la misma clase, al igual que diferentes condiciones de visualización.

(54)

Ilustración 8 Comando LabelMe



Fuente: Autor

6.5.6. Supervisely

Es la plataforma elegida por empresas e investigadores para gestionar y procesar una extensa variedad de datos, desde imágenes y videos hasta datos 3D complejos. Aparte de ser una simple herramienta de etiquetado, Supervisely es una herramienta completa que permite personalizar y combinar varios modelos de aprendizaje automático para adaptarse a las necesidades de cada proyecto (55).

Supervisely brinda la oportunidad de ejecutar arquitecturas tipo MMDetection, los procesos de entrenamiento y prueba en esta plataforma, se realizan en una estación de trabajo con las configuraciones de una CPU Intel Xeon, GPU Nvidia Quadro RTX5000 de 16 GB de RAM (56).

6.5.7. YOLO V-8

YOLO v8 es un modelo de deep learning de última generación que fue diseñado para la detección de objetos en tiempo real aplicaciones de visión por ordenador. Ha transformado la detección de objetos con su arquitectura y algoritmos avanzados, permitiendo al modelo ser más preciso y eficiente en escenarios en tiempo real. (57)

YOLO fue presentado por primera vez dentro de industria de visión por ordenador en el 2015 en un artículo publicado por Joseph Redmon et al. Titulado “You Only Look Once: Unified, Real-Time Object Detection” en donde replanteaba la identificación de objetos, presentándola como un problema de regresión de una sola fase, comenzando con los píxeles de la imagen y pasando al cuadro delimitador y a las probabilidades de clase. El enfoque que propuso se basa en el principio “unificado”, que hizo posible la predicción simultánea de múltiples recuadros delimitadores y probabilidades de clase, lo que aumentaba la velocidad y la precisión. Desde que se creó en el 2016 hasta el 2023, YOLO ha evolucionado a paso acelerado. A pesar de que Joseph Redmon (autor inicial) detuvo su trabajo en la

versión de YOLO-v3, la efectividad y potencial del concepto central “unificado” han sido desarrollados por diversos autores y la última versión de YOLO es YOLO-v8 (58).

En enero de 2023 se publicó YOLO-v8 por medio de Ultralytics (que también lanzó YOLO-v5), aunque aún quedan muchas características que añadir a su repositorio, a comparación con las antiguas versiones, demuestra superioridad como nuevo estado del arte de YOLO. Se demostró que al comparar YOLO-v8 con YOLO-v5 y YOLO-v6 entrenados con una definición de imagen de 640 píxeles, todas las variantes de YOLO-v8 dan un mejor resultado con un número semejante de parámetros, lo que significa que han realizado reformas arquitectónicas eficaces desde la perspectiva del hardware (58).

YOLO innova el campo de la detección de objetos con la reformulación de la tarea en cuestión como un problema de regresión, esto significa que, en lugar de clasificar las regiones de interés, las coordenadas exactas de los cuadros delimitadores son predichas directamente (59).

Yolo-v8 se centra en los avances más recientes de aprendizaje profundo y visión por ordenador, está dotado con un rendimiento inigualable en cuanto a velocidad y precisión respecta. Tiene un diseño aerodinámico que lo hace conveniente para una gama de aplicaciones y que sea de fácil adaptabilidad a diversas plataformas de hardware (60). Estos son los pasos básicos del principio de funcionamiento de YOLO-v8:

1. Procesamiento de entrada: YOLO v8 procesa una imagen de entrada, divide la misma en una cuadrícula que su tamaño por lo general es de 13x13 o 26x26, según el tipo específico. Cada celda de esta cuadrícula está encargada de predecir los objetos dentro de su dominio espacial (61).
2. Extracción de características: La red emplea una red neuronal convolucional profunda (CNN) para discernir características complejas de una imagen de entrada. La

arquitectura de la red tiene como base modelos predeterminados como ResNeXt o Darknet (61).

3. Predicción de caja delimitadora: YOLO v8 estima la posición y tamaño de objetos dentro de una imagen por medio de regresión de las coordenadas de la esquina superior izquierda, la anchura y la altura del cuadro. Igualmente, asigna una puntuación de confianza que refleja la certeza de que la detección del cuadro predicho, contenga el objeto (61).
4. Predicción de clase: Además de predecir los cuadros delimitadores, YOLO v8 asigna probabilidad a cada celda de la región de interés. Esto implica que el modelo no solo detecta objetos, sino que también es capaz de clasificar los objetos identificados (61).

Los modelos YOLO que han sido preentrenados en bases de datos masivas, como COCO e ImageNet, muestran una dualidad única, otorgándoles la capacidad de actuar como el maestro y el alumno. Presentan predicciones altamente precisas para las áreas que han sido entrenados (capacidad de maestro), y tienen la capacidad de aprender nuevas clases con gran facilidad (capacidad de alumno) simultáneamente. Así mismo, son más rápidos para entrenar y tienen la ventaja de generar una mejor precisión con modelos pequeños. Se puede entrenar con solamente una GPU, lo que los hace más asequible. YOLO v8 es la iteración más reciente de estos modelos, se ha realizado algunas modificaciones importantes con respecto a versiones anteriores, como la detección sin anclajes, la incorporación de convoluciones C3 y el aumento de mosaicos (59).

6.5.8. Comet

Comet es una plataforma de meta aprendizaje automático destinada para facilitar a los usuarios y equipos de IA a desarrollar modelos de aprendizaje automático confiables (62). Es útil para registrar datos, métricas, parámetros, multimedia y más mientras se entrena el modelo, también se puede supervisar por medio de una interfaz web que

agilite la comparar, analizar y optimizar varios experimentos. Permite a los científicos de datos, repetir de manera rápida, aumenta la transparencia y la reproductibilidad, así como también ayuda en la creación de modelos de producción (63).

Esta plataforma impulsa el machine learning y a la vez promueve la productibilidad, reproducibilidad y colaboración, sin importar las herramientas que se estén utilizando para entrenar y desarrollar modelos: gestionados, open-source o in-house (64) .

6.5.9. Roboflow

Es una herramienta que simplifica tarea de visión por ordenador en el área del aprendizaje profundo. Facilita a los desarrolladores diseñar aplicaciones de visión por ordenador, sin importar sus habilidades o experiencia, permite modelos de detección y clasificación de objetos. Roboflow tiene las siguientes funciones: anotar conjuntos de datos, procesar conjuntos de datos, fusión de proyectos y conjunto de datos, comprobación del estado de los conjuntos de datos, exportación de conjuntos de datos, entrenar modelos (65).

Así como también mejora la recopilación de datos, procesamientos y técnicas de desarrollo de modelos. Cuenta con un conjunto de datos públicos a disposición de los usuarios y también permite que los mismos suban sus datos personalizados propios. Dentro del procesamiento de datos, incluyen fases como la orientación de las imágenes, cambio de tamaño, contraste y aumento de datos. Roboflow se emplea en montón de áreas dentro de la visión por ordenador como en ciertos casos como en la detección de fugas de gas, detección de malas hierbas frente a plantas, mantenimiento de aviones, estima daños en tejados, imágenes por satélite, coches que se conducen solos, contadores de tráfico, limpieza de basura y una variedad de cosas más (66).

6.5.10. Data Augmentation

Es el método con el cual se crean permutaciones de imágenes dentro de un conjunto de datos para generar nuevas imágenes. Esto permite que un modelo aprenda a identificar con mayor precisión los objetos en diferentes condiciones. Se puede aumentar una imagen aumentando o disminuyendo el brillo, así como también cambiando el ángulo. Data Augmentation puede ser útil en una serie de tareas de aprendizaje automático como el procesamiento de audio y visión por ordenador (67).

Existe una amplia gama de aumento de datos, estas son unas de las más comunes:

- Rotación: Las imágenes son rotadas en diferentes grados (por ejemplo, 90, 180). Esto es útil si se espera que un modelo tenga que identificar objetos que están en ángulo. Un aumento habitual es la rotación de 90 grados (67).
- Recorte aleatorio: Se recorta las imágenes en una posición aleatoria. Lo que puede dar lugar a que se recorte a través de un objeto, esto permite a un modelo aprender mejor a identificar objetos que no están completamente a la vista (67).
- Exposición: Aumento o disminución del brillo de una imagen, útil para identificar objetos en zonas con iluminación variable (67).
- Desenfoque: Aplica un efecto de desenfoque (67).
- Voltar: Voltea una imagen de izquierda a derecha o de arriba hacia abajo, es útil cuando está reconociendo texto (67).
- Saturación: La intensidad de color cambia, se usa cuando las condiciones de producción de iluminación varían (67).
- Ruido aleatorio: Aplicación de píxeles blancos y negros, esto hace a la imagen más borrosa (67).

- Aumento de mosaico: Combina algunas imágenes, se usa para trabajos con imágenes aéreas (67).

VII. MATERIALES Y METODOS

7.1. Tipo de estudio

El estudio es de tipo experimental, ya que se centra en el desarrollo y aplicación de un modelo basado en inteligencia artificial (IA) para segmentar y clasificar células de la mucosa vaginal en imágenes microscópicas. Además, se entrenó y evaluó el modelo utilizando un conjunto de datos anotados y se compararon los resultados con los métodos tradicionales de citología vaginal.

Se implementaron el métodos mixtos, ya que se utilizaron tanto métodos cuantitativos como cualitativos. Los métodos cuantitativos se aplicaron en el análisis de datos generados por el modelo de IA y su comparación con métodos tradicionales (medición de precisión, sensibilidad, y otras métricas de evaluación). Por otro lado, los métodos cualitativos fueron utilizados para el análisis y anotación de las imágenes citológicas bajo la supervisión de expertos en la materia.

7.2.Ubicación

El estudio se realizará en el laboratorio de patología de la Universidad Técnica de Machala en la Facultad de Ciencias Agropecuarias, ubicada en Avenida Panamericana Km. 5 ½ vía a Pasaje, en la ciudad de Machala, Provincia de El Oro con una latitud de S3°15'31" y una longitud de O79°57'37.91", con un clima cálido tropical que oscila entre 17°C y 34°C en promedio y con una altura de 6 msnm.

Ilustración 9 Ubicación de la Facultad de Ciencias Agropecuarias



Fuente: Google Maps, 2024

7.3. Metodología

7.3.1. Toma de muestra

Se empieza colocando la perra en cuadrípedación sobre la mesa de consulta, mientras la persona asistiendo debe levantar la cola y procurar que este lo más lejos que se pueda de la vulva. Se procede a limpiar los labios vulvares y el área perineal con una solución antiséptica y lavar con agua temperada, seguidamente se insertar un hisopo dentro de la vagina a 45° y se hace un ligero movimiento de rotación para conseguir la muestra, sobre un portaobjetos hacer movimientos ligeros mientras se lo gira, se fija con alcohol y se deja secar al aire libre. Por último, se tiñe la placa con colorante de Diff-Quick y se procede a observar en el microscopio y la toma de imagen con lente 40x.

7.3.2. Obtención de las imágenes

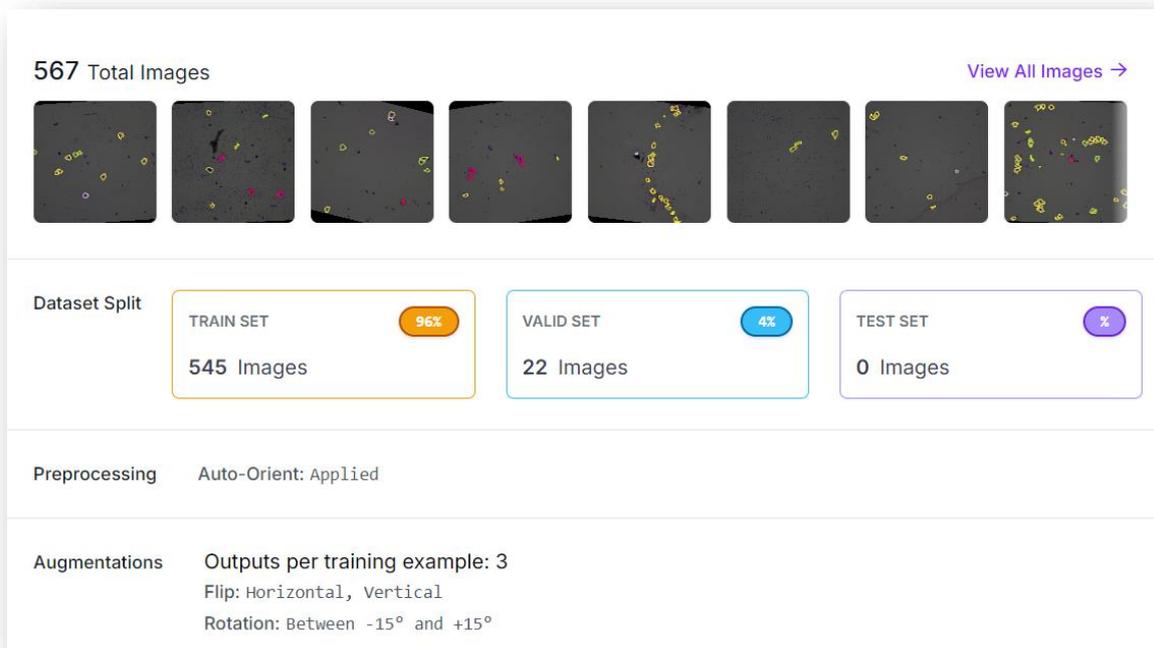
Para la toma de imágenes desde la placa portaobjeto, se utilizó el microscopio Nikon eclipse E200 y la cámara Mshot MS60. Se observó la placa con lente de 4x, 10x, y al

llegar a 40x se realizó la toma de imágenes con el sistema de análisis de imagen Mshot de las regiones donde se pudo observar los cuatro tipos de células epiteliales de la mucosa vaginal. Estas imágenes se dividieron en dos grupos, para entrenamiento y otras para validación del modelo de IA.

7.3.3. Conjunto de datos

Para este proyecto, se utilizó un método apoyado en el aprendizaje supervisado, donde se recopiló un conjunto de datos de 204 imágenes, cada imagen digitalizada histopatológica se analizó bajo la supervisión de una persona experta en el área y se hicieron anotaciones de todas estas células con el comando LabelMe de Python, en donde se usó polígonos los cuales sirvieron para delimitar las células en la imagen. Posteriormente se corrigieron las anotaciones en la plataforma la plataforma de visión por computador Supervisely. Posteriormente a ello se utilizó la herramienta de anotación Roboflow para crear Data Augmentation, que sirvió crear permutaciones de imágenes existentes dentro del conjunto de datos y así crear nuevas imágenes para mejorar la capacidad del modelo y que funcione de forma más efectiva, con lo antes mencionado se pudo generar un total de 567 imágenes, las cuales se dividieron en 545 para entrenamiento y 22 para validación.

Ilustración 10 Data Set



Fuente: Autor

Ilustración 11 Ejemplo del conjunto de datos generado



Fuente: Autor

7.3.4. Segmentación de las imágenes

Para la detección de tipos celulares en el epitelio vaginal, se optó por el modelo YOLOv8l-seg, por su precisión y que se ajusta a las limitaciones de hardware impuestas por la plataforma Google Colab, que proporciona recursos informáticos en la nube como almacenamiento, memoria ram, capacidad de procesamiento y unidades de procesamiento gráfico (GPU) que son esenciales para el entrenamiento de modelos, trabajar con ciencia de datos, aprendizaje profundo, redes neuronales y aprendizaje automático. Los recursos y librerías provistos por Google Colab son:

GPU: Nvidia L4 – 22.5 GB

CPUs: 12

RAM: 53.0 GB

DISCO: 201.2 GB

Python Version: 3.10.12

Torch: 2.3.1+cu121

Ultralytics Version: YOLOv8.2.72

Tabla 1 Modelos de YOLOv8

Model	size (pixels)	mAP ^{box} 50-95	mAP ^{mask} 50-95	Speed CPU ONNX (ms)	Speed A100 TensorRT (ms)	params (M)	FLOPs (B)
YOLOv8n-seg	640	36.7	30.5	96.1	1.21	3.4	12.6
YOLOv8s-seg	640	44.6	36.8	155.7	1.47	11.8	42.6
YOLOv8m-seg	640	49.9	40.8	317.0	2.18	27.3	110.2
YOLOv8l-seg	640	52.3	42.6	572.4	2.79	46.0	220.5
YOLOv8x-seg	640	53.4	43.4	712.1	4.02	71.8	344.1

Fuente: Ultralytics

7.3.5. Entrenamiento

La detección de cuatro tipos celulares del epitelio vaginal se considera una tarea de clasificación de una sola clase u objeto a detectar y para su entrenamiento se mantuvo la mayor parte de parámetros con sus valores por defecto, únicamente se modificaron el tamaño del lote o **batch=4**, la cantidad de épocas o **epochs=70**, el tamaño de entrada de la red o **imgsz** se configuró en **1280 × 1280** para mantener una resolución similar a la imagen original y evitar perder información al redimensionar a valores inferiores. Estas configuraciones, permitieron entrenar el modelo y no superar el consumo máximo de hardware permitido por la plataforma **Google Colab**, de no ser así la plataforma hubiese detenido el entrenamiento.

Los hiperparámetros configurados para el entrenamiento del modelo fueron los siguientes:

- task=segment
- mode=train
- model=yolov8l-seg.pt
- data={dataset.location}/data.yaml
- epochs=70
- batch=4
- imgsz=1280
- save_period=1
- overlap_mask=False

La métrica de evaluación principal en YOLOv8 es mAP50 y mAP50-95 (precisión promedio media) que se utiliza para las tareas de detección de objetos.

Hay otros tipos de métricas en tareas de visión por computadora estándar para la evaluación del desempeño, tales como precisión, recuperación y puntuación F1. Dado que nuestro objetivo es diagnosticar mediante la búsqueda de cuatro tipos celulares de la mucosa vaginal en una imagen microscópica y proporcionar una base para futuros proyectos, se seleccionan las métricas de evaluación del desempeño siguientes:

- **TP** (Verdadero Positivo) = número de Verdaderos Positivos, es decir, el número de células que son células reales entre las detectadas. Es decir, cuando nuestro modelo predice correctamente.
- **FP** (Falso Positivo) = número de falsos positivos, es decir, el número de células que no son células reales entre las detectadas. Es decir, cuando no hay células en la imagen de entrada y el algoritmo propuesto las detecta.
- **FN** (Falso negativo) = número de falsos negativos, es decir, el número de células reales que no se han detectado. Es decir, cuando hay células en la imagen de entrada y el algoritmo propuesto no las detecta.
- **Confidence** = la puntuación de confianza muestra qué tan seguro está el modelo YOLO con respecto a la presencia de la región de la célula.
- **R ó Recall** (sensibilidad) = $TP / (TP+FN)$
- **P ó Precision** (valor predictivo positivo) = $TP / (TP+FP)$. Muestra hasta qué punto la detección positiva de la célula es realmente correcta

- **F-measure** ($F1 = 2 * (Precision * Recall) / (Precision + Recall)$). Es la media armónica de precisión y recuperación. Cuanto mayor sea la puntuación F1, mejor será el algoritmo.

7.4. Materiales y equipos

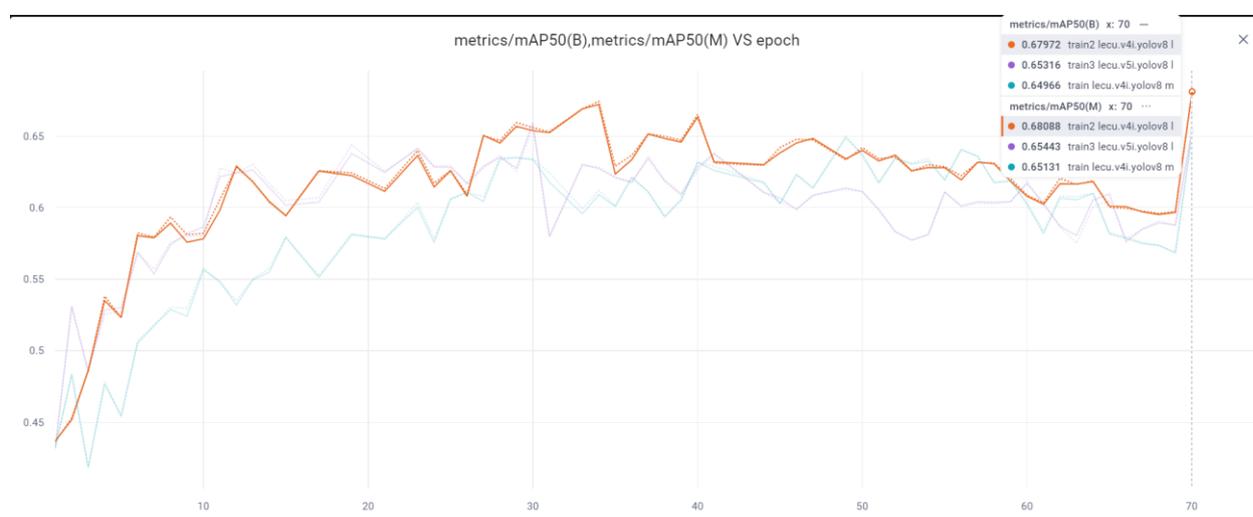
- Hisopo
- Microscopio electrónico
- Cámara Nikon eclipse E200 y cámara Mshot MS60
- Porta objetos
- Solución salina
- Tinción Diff-Quick Computadora
- Software de procesamiento de imágenes
- Modelo de detección de objetos y segmentación de imágenes
- Plataforma de visión por computador
- Herramienta de anotación

VIII. RESULTADOS

8.1. Selección de modelo para entrenar

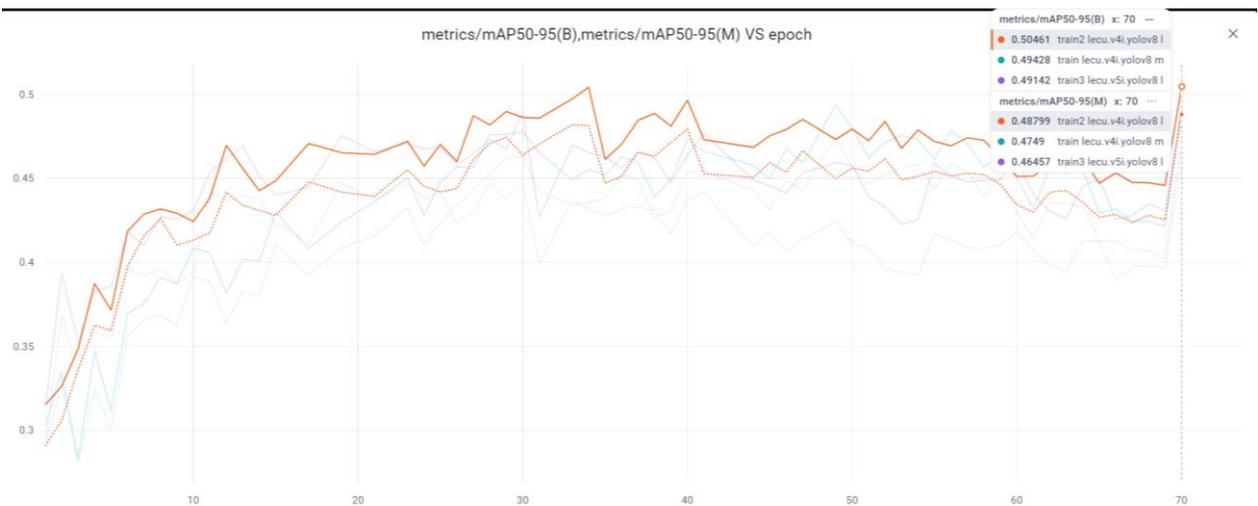
Tras el monitoreo y rastreo del ciclo de vida de varios modelos entrenados e iterados entre 70 épocas, batch de 1 y 4, con los modelos YOLOv8m-seg y YOLOv8l-seg, se obtuvieron las gráficas mostradas en la parte inferior utilizando la plataforma ML de Comet que representan ejecuciones de horas de entrenamiento. A partir de estas graficas se realizó un rastreo y comparación para llegar a explicar el mejor modelo obtenido el mismo que esta graficado en color naranja “*train2 lecu.v4i.yolov8 l*”, se observa como en la época 40 las métricas mAP50 y mAP50-95 son las más altas en comparación con los demás modelos por ende es que se usó.

Ilustración 12 Gráfica de rastreo de los modelos



Fuente: Autor

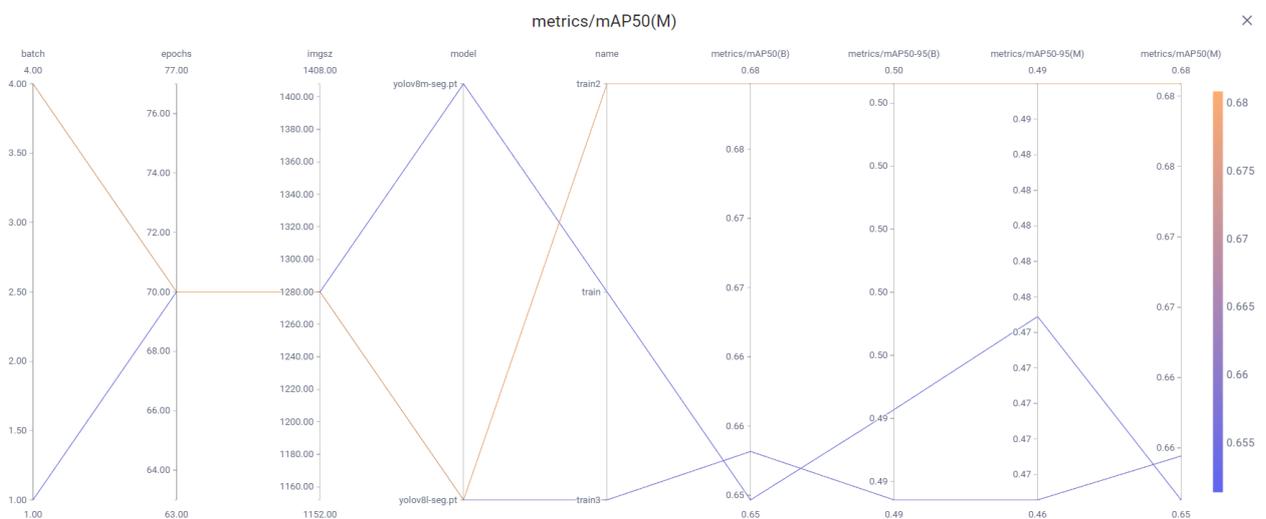
Ilustración 13 Gráfica de rastreo de los modelos



Fuente: Autor

A continuación, se muestra otra forma de visualizar de manera general como las métricas y parámetros influyen en cada modelo entrenado a través de una tabla de coordenadas paralelas. El modelo representado por la gráfica en color naranja es el mejor modelo entrenado que ya se había definido anteriormente.

Ilustración 14 Gráfica general del rastreo de los modelos



Fuente: Autor

8.2.Resultados de entrenamiento

Se puede apreciar que han completado 78 épocas de entrenamiento en aproximadamente 3.7 horas. Cada época representa una pasada completa de todo el conjunto de datos de entrenamiento. El optimizador utilizado para ajustar los parámetros del modelo ha sido guardado en dos ubicaciones diferentes. Se ha realizado una validación del modelo utilizando los pesos obtenidos en la mejor época.

Ilustración 15 Detalles del modelo

```
70 epochs completed in 1.794 hours.
Optimizer stripped from runs/segment/train2/weights/last.pt, 92.5MB
Optimizer stripped from runs/segment/train2/weights/best.pt, 92.4MB

Validating runs/segment/train2/weights/best.pt...
Ultralytics YOLOv8.2.67 Python-3.10.12 torch-2.3.1+cu121 CUDA:0 (NVIDIA L4, 22700MiB)
YOLOv8l-seg summary (fused): 295 layers, 45,914,972 parameters, 0 gradients, 220.1 GFLOPs
2.02it/s]

```

Class	Images	Instances	Box(P)	R	mAP50	mAP50-95	Mask(P)	R	mAP50	mAP50-95
all	22	522	0.635	0.643	0.68	0.505	0.634	0.642	0.681	0.488
Anuclear	15	42	0.596	0.527	0.557	0.417	0.596	0.527	0.565	0.423
Intermedia	22	310	0.805	0.895	0.897	0.635	0.803	0.892	0.894	0.61
Parabasal	10	37	0.454	0.595	0.604	0.474	0.454	0.595	0.607	0.446
Superficial	20	133	0.685	0.556	0.661	0.491	0.685	0.556	0.658	0.473

```
Speed: 1.0ms preprocess, 46.5ms inference, 0.0ms loss, 2.7ms postprocess per image
Results saved to runs/segment/train2
```

Fuente: Autor

Detalles del Modelo:

Versión: YOLOv8l-seg, una variante del modelo YOLO optimizada para segmentación.

Entorno: Se utilizó Python 3.10.13, PyTorch 2.3.1121 y una GPU NVIDIA.

Arquitectura: El modelo consta de 295 capas, 45.9 millones de parámetros y requiere 220 GFLOPs para realizar una inferencia.

8.2.1. Resultados de la Validación

Métricas: Se muestran varias métricas para evaluar el rendimiento del modelo en la tarea de segmentación, incluyendo:

mIoU (Mean Intersection over Union): Mide la proporción de área de solapamiento entre las predicciones y las etiquetas verdaderas. Un valor más alto indica una mejor coincidencia.

mAP (mean Average Precision): Mide la precisión promedio de las detecciones.

Otras métricas: Como recall, precision, F1-score, etc., que proporcionan información adicional sobre el rendimiento del modelo.

Clases: Los resultados se presentan para cada una de las clases de células (Anuclear, Intermedia, Parabasal, Superficial).

Tiempo de Procesamiento: Se indica el tiempo promedio que tarda el modelo en procesar una imagen, incluyendo el preprocesamiento, la inferencia y el postprocesamiento.

Buen Rendimiento: Los valores de mIoU y mAP son relativamente altos, lo que sugiere que el modelo está realizando una buena segmentación de las diferentes clases de células.

Equilibrio entre las Clases: El modelo parece estar generalizando bien a todas las clases, sin un sesgo hacia ninguna en particular.

Eficiencia: El tiempo de procesamiento por imagen es relativamente bajo, lo que indica que el modelo es eficiente computacionalmente.

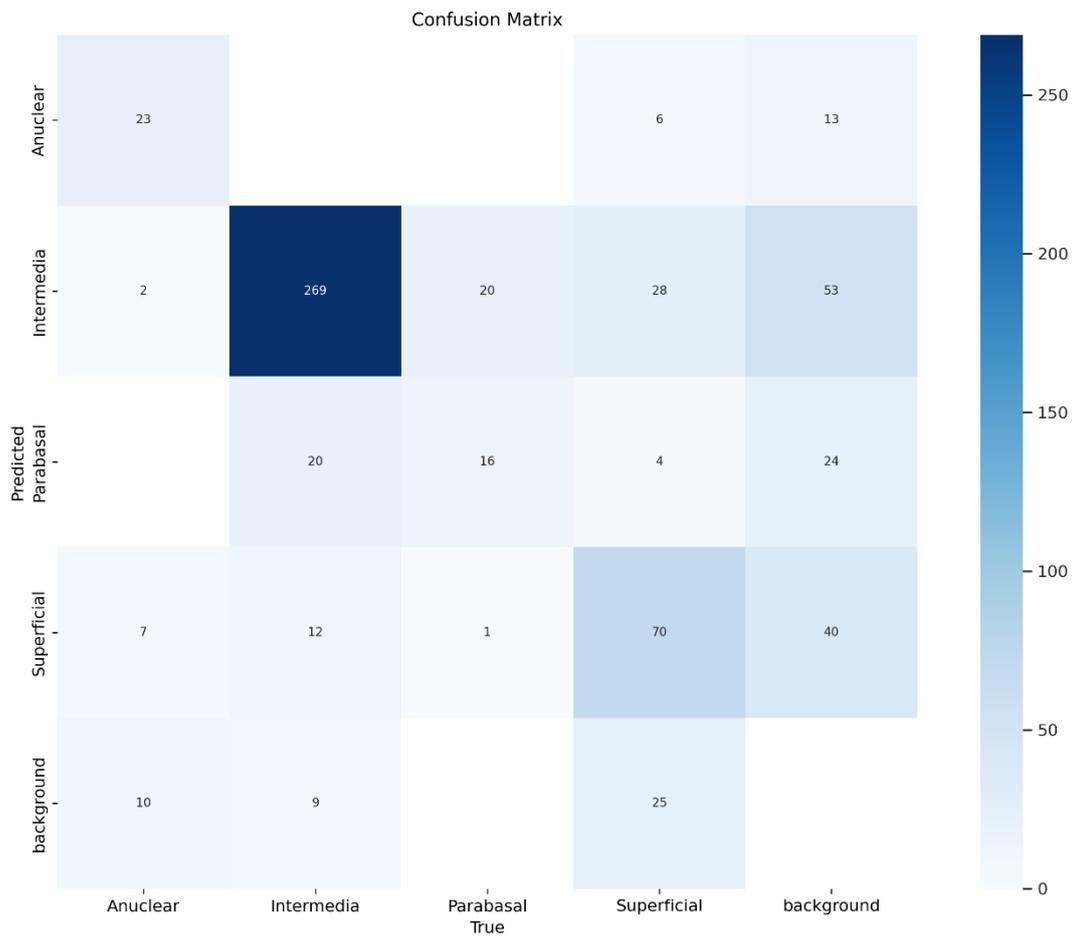
A partir de las métricas generadas del entrenamiento se calcula la métrica F1:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2 \times 0.635 \times 0.643}{0.635 + 0.643}$$

$$F1 = 0.6389$$

8.2.2. Matriz de Confusión

Ilustración 16 Matriz de confusión



Fuente: Autor

En el conjunto de datos propuesto, el conjunto de validación tiene un total de 22 imágenes de histopatología con células etiquetados o anotados. El modelo YOLOv8 entrenado se aplica al conjunto de validación y se evalúa su rendimiento.

Tomando como ejemplo la clase anuclear, en esta clase tiene un total de 42 células anotadas, 23 objetos se detectan correctamente (TP = 23), se pasan por alto 13 células (FN = 13) y 6 objetos adicionales se detectan erróneamente como células Superficial (FP = 6). La precisión, la recuperación y la puntuación F1 del método de referencia en el conjunto de prueba son 0,635, 0,643 y 0,6389 respectivamente.

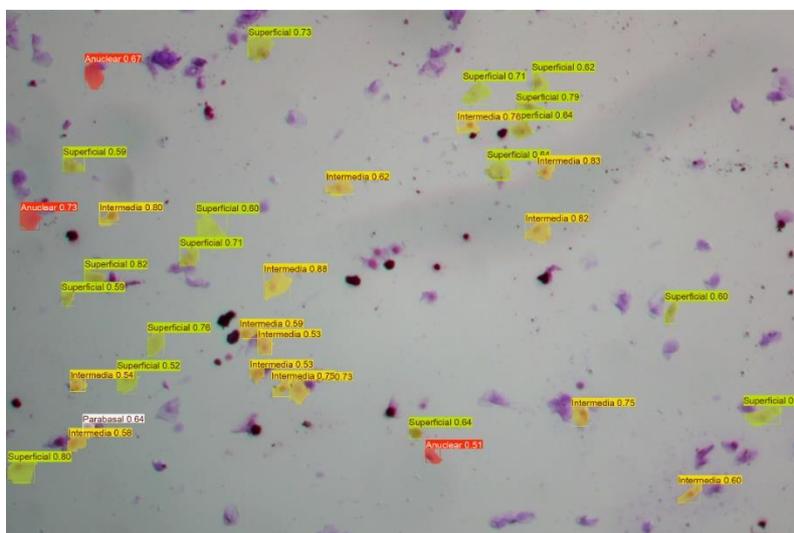
Tabla 2 Resumen del rendimiento del modelo de referencia (YOLOv8) en el conjunto de validación

Parameter	Value
Precision (Box)	0.635
Recall (Box)	0.643
mAP50 (Box)	0.68
mAP50-95 (Box)	0.505
Precision (Mask)	0.634
Recall (Mask)	0.642
mAP50 (Mask)	0.681
mAP50-95 (Mask)	0.488
F1-Score	0.6389

Fuente: Autor

8.2.3. Visualización de Resultados

Ilustración 17 Resultados de la detección de células



Fuente: Autor

En la imagen de ejemplo se indica que el modelo ha detectado y clasificado las células en las siguientes categorías: tres células anucleares, quince células intermedias, una célula parabasal y diecisiete células superficiales. Lo que significa que el modelo está segmentando las diferentes células correctamente.

Ilustración 18 Resultados tomando una imagen como referencia

```
image 1/1 /content/drive/MyDrive/Celulas/1.jpg: 864x1280 3 Anuclears, 15 Intermedias, 1 Parabasal, 17 Superficials, 33.4ms  
Speed: 8.9ms preprocess, 33.4ms inference, 4.2ms postprocess per image at shape (1, 3, 864, 1280)  
>> OK <<
```

Fuente: Autor

Interpretando la imagen superior de los resultados del ejemplo, podemos ver que el tiempo que el modelo tardó en procesar la imagen y generar los resultados fue de 33.4ms, un tiempo relativamente bajo.

El tiempo empleado en cada una de las etapas del proceso fueron: en el preprocesamiento de imágenes fue de 8.9ms, en la inferencia del modelo fue de 33.4ms y en el postprocesamiento de los resultados fue de 4.2ms.

Per image at shape (1,3,864,1280), se refiere al análisis o procesamiento de cada imagen de manera individual dentro del conjunto de datos. Esto nos especifica que estos tiempos comprenden al procesamiento de una sola imagen con las dimensiones indicadas anteriormente: 1 imagen, 3 canales de color, 864 pixeles de ancho y 120 pixeles de alto.

8.3.Resultados de la app

Referente a la aplicación CytoCells, se realizó varias pruebas para evaluar su rendimiento en cuanto al tiempo de procesamiento y la calidad de los resultados. Sin embargo, se debe considerar que el desempeño es notablemente variable, esto debido a que depende bastante de la complejidad de las imágenes, las dimensiones de las células y la calidad de la imagen de entrada.

También es necesario tener en cuenta que hay ciertas restricciones y observaciones sobre su funcionamiento que se debe mejorar, como:

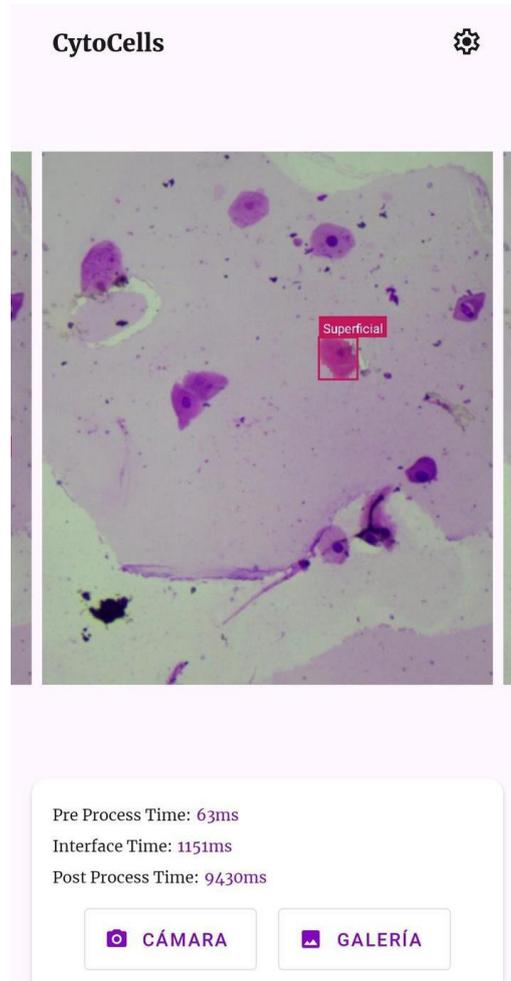
- No procesa imágenes con células agrupadas

- Las imágenes borrosas no dan resultados precisos
- En ciertos casos no detecta el citoplasma completo, dividiendo la célula en dos y tomando un resultado doble de una misma célula.
- No procesa imágenes que contengan muchas células
- No procesa todas las células en ciertas imágenes
- Trabaja mejor cuando en la imagen hay distancia entre célula y célula
- No detecta células con el citoplasma que estén poco pigmentado
- Se visualiza mejor con la opción de que la app presente los resultados en imágenes por separado (una célula detectada por imagen), aunque cuando presenta los resultados en una sola imagen, algunas veces detecta con más precisión las células.
- Solo está disponible para dispositivos Android
- No es posible hacer uso de la opción de tomar una foto directo desde la cámara del celular, por lo que los teléfonos tienen una alta resolución de imagen y la app no tiene la capacidad de procesar imágenes de mas de 1600x1600px.

Ilustración 19 Logo de la aplicación

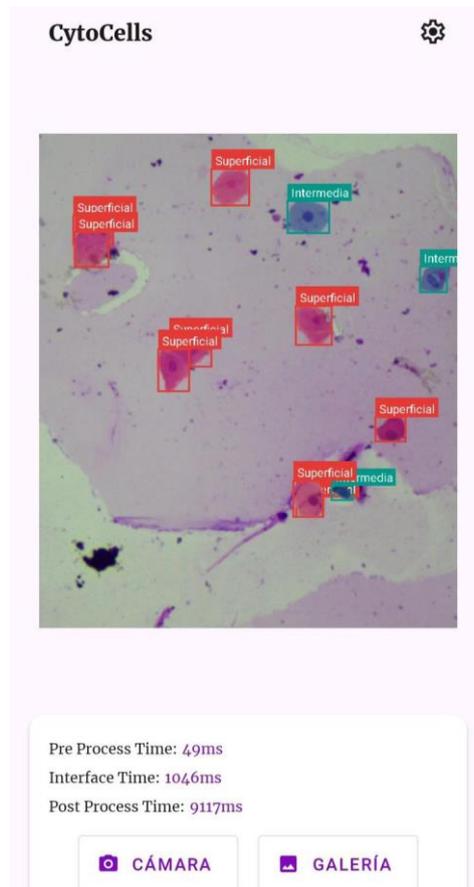


Ilustración 20 Ejemplo de resultados presentados por separado



Fuente: Autor

Ilustración 21 Ejemplo de resultados presentados en una sola imagen



Fuente: Autor

8.3.1. Resultados de la muestra de validación

A continuación, se presenta los resultados obtenidos desde un teléfono móvil, donde se utilizaron 10 imágenes diferentes, se cargó las fotografías dos veces, esto dado a que la aplicación cuenta con una opción para presentar los resultados ya sea que se observe todas las células detectadas en una sola imagen o separa los resultados de la misma desglosados en diferentes imágenes donde se puede observar la detección de todas las células dentro de la imagen de forma individual para evaluar la capacidad de detección de las células, considerando los parámetros de Pre Process time, Interface Time, Post Process Time, TP (true positive o

positivo verdadero), FP (false positive o falso positivo), FN (false negative o falso negativo), sensibilidad y precisión.

Para determinar el porcentaje de sensibilidad y precisión de la aplicación se usaron las siguientes métricas:

$$Sensitivity = \frac{TP}{TP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

Tabla 3 Funcionamiento de la aplicación CytoCells

Tipo de dispositivo: Telefono celular		Modelo: Redmi Note 11					Sistema Operativo: MIUI Global 13.0.16				
Resultados por imágenes separadas											
Número de Imagen	Imagen #1	Imagen #2	Imagen #3	Imagen #4	Imagen #5	Imagen #6	Imagen #7	Imagen #8	Imagen #9	Imagen #10	
PreProcess Time	52ms	54ms	56ms	64ms	38ms	27ms	26ms	23ms	30ms	33ms	
Interface Time	1085ms	1085ms	1084ms	1084ms	1085ms	1042ms	1072ms	1032ms	1044ms	1038ms	
PostProcess Time	9419ms	3265ms	5411ms	10464ms	6612ms	7060ms	2595ms	9345ms	6985ms	3119ms	
TP (True Positive)	10	7	3	5	4	12	5	16	10	5	
FP (False Positive)	2	4	2	5	2	4	4	4	3	2	
FN (False Negative)	1	0	6	0	4	6	7	3	1	2	
% Sensibilidad	90,90%	100%	33,33%	100%	50%	66,66%	41,66%	84,21%	90,90%	71%	
% Precisión	83,33%	63,63%	60%	50%	66,66%	75%	55%	80%	76,92%	71,42%	
Resultados por una sola imagen											
Número de Imagen	Imagen #1	Imagen #2	Imagen #3	Imagen #4	Imagen #5	Imagen #6	Imagen #7	Imagen #8	Imagen #9	Imagen #10	
PreProcess Time	76ms	60s	62ms	74ms	54ms	26ms	29ms	29ms	27ms	43ms	
Interface Time	1152ms	1039ms	1031ms	1043ms	1091ms	1045ms	1040ms	1050ms	1055ms	1045ms	
PostProcess Time	9404ms	3274ms	5871ms	10509ms	6625ms	7078ms	2597ms	9355ms	6979ms	3111ms	
TP (True Positive)	8	7	3	5	4	14	6	16	11	5	
FP (False Positive)	3	3	2	5	2	3	3	3	2	2	
FN (False Negative)	1	0	6	0	4	5	6	3	1	2	
Sensibilidad	88,80%	100%	33,33%	100%	50%	73%	50%	84,21%	91,66%	71,42%	
Precisión	72,72	70%	60%	50%	60%	82,35%	66,66%	84,21%	84,61%	71,42%	

Fuente: Autor

Al apreciarse los resultados en la tabla de pre y post procesamiento junto a sus positivos verdaderos y falsos y sumado a sus falsos negativos, los resultados oscilan entre el 50% y el 84.61 % al analizar las muestras en una sola imagen. Estos porcentajes claramente van

de la mano con los datos arrojados al haberse tomado la muestra como el tiempo de pre procesado que, aunque no es el más veloz si es evidente como su rendimiento es mayor en la imagen #9 en comparación a la imagen #4 superándolo casi en todos sus aspectos excepto en la sensibilidad que, aunque la imagen #4 presenta un 100% de sensibilidad, los factores anteriormente mencionados son los detonantes para un resultado por debajo de lo esperado.

Un factor común es que al tomarse las imágenes de las muestras por separado la imagen #4 vuelve a ser la peor evaluada por los mismos datos frente a mejores resultados en la imagen #1 aunque esto no podría ser un elemento ejecutante de la evaluación, ya que hay que destacar las limitantes no solo de la aplicación, sino de los dispositivos en donde se encuentra instalada, siendo el Redmi Note 11 un dispositivo de gama baja posee un procesador medianamente aceptado en el mercado y puede verse impedida de un mejor procesamiento de los detalles al momento de realizar la muestra precisamente ligado al limitado nivel de procesado de datos y de rendimiento que posee su procesador, por lo que dichos resultado podrían experimentar una mejora significativa al realizarse mejores pruebas en dispositivos que encuentren un balance entre sus periféricos de entrada junto a mejoras y correcciones dentro del funcionamiento de la misma aplicación.

En este estudio, la precisión de detección de las células fue 0.635 para el conjunto de validación de cajas delimitadoras (Box) y 0.634 para la máscara de segmentación (Mask). Esto significa que el modelo identificó correctamente el 63.5% de las células predichas como positivas. Por otra parte, la sensibilidad obtenida fue de **0.643** tanto para el conjunto de validación de cajas delimitadoras como para la máscara de segmentación. Esto indica que el modelo fue capaz de detectar el 64.3% de todas las células reales presentes en las imágenes.

En definitiva, los resultados de la aplicación son fluctuantes, esto nos sugiere que el modelo aún tiene dificultades detectando ciertos tipos de células o en tal caso, ciertos tipos de imágenes. Los valores de TP, FP Y FN nos indican que se puede identificar correctamente algunas células, pero aún hay leves errores al momento de clasificarlas. El proceso de análisis de muestras que suele realizar un clínico se redujo considerablemente, aunque un factor limitante para la automatización sería que abrir directamente la cámara desde la aplicación para tomar una foto no funciona, por lo que el uso se vuelve más tedioso para el usuario.

8.4.Discusión

El uso de IA en este estudio, permitió tener una visión amplia dentro del campo diagnóstico, debido que no hay muchas referencias de diagnóstico por imagen en citología vaginal usando este método, esto también es resaltado en el estudio realizado en 2022 por Bouhali y sus colaboradores (68), donde resaltan que en la salud humana se ha visto grandes avances en la aplicación de IA en varias áreas, a diferencia de que en la medicina veterinaria estas tareas de diagnóstico por imagen son realizadas por expertos en el área y que sin embargo, la interpretación de imágenes puede ser algo subjetiva.

Así mismo, Wolcott y sus colaboradores (69) se centran en que un obstáculo importante para el desarrollo de softwares para analizar ciclos estrales, es que hay bases de datos muy pobres, lo que obliga a los investigadores obtengan sus propias imágenes citológicas, lo que concuerda con este estudio, ya que se tuvo que hacer una base de datos propia para el entrenamiento del modelo.

El objetivo del estudio de Kim y sus colaboradores (70), fue determinar la precisión, especificidad y sensibilidad de un software de IA para el diagnóstico de edema pulmonar cardiogénico canino con ayuda de radiografías torácicas, tomando como referencia la

interpretación de un cardiólogo veterinario certificado. En este caso, se consideraron los mismos parámetros para evaluar el modelo de IA entrenado, y se tomó como referencia la interpretación de una visión experta en el tema. En 2015 Andrews y sus colaboradores (7), realizaron una encuesta a más de 100 veterinarios en el estado de Carolina del Sur, para determinar el impacto de los dispositivos móviles en la clínica veterinaria, como se usan los recursos tecnológicos móviles actualmente dentro del medio veterinario. En los resultados se pudo apreciar que la mayoría de los veterinarios concuerdan que los dispositivos móviles son de gran utilidad para tener acceso a literatura, a protocolos de tratamientos pre establecidos, datos clínicos, para programar citas, para el seguimiento de pacientes y para la prevención de crisis en la salud pública, también establecieron que puede mejorar el tratamiento y cuidado de los pacientes. Es por esto que CytoCells será de gran utilidad y debido a que no hay una variedad de aplicaciones que se dediquen a detectar células de la mucosa vaginal, será una innovación que a futuro se convertirá en una ayuda para los clínicos en la consulta veterinaria diaria.

En un artículo publicado en 2023 sobre el entrenamiento y validación de un nuevo sistema de imágenes no invasivo para descartar malignidad en masas subcutáneas y cutáneas caninas mediante aprendizaje automático en 664 masas (71), se resaltó que la precisión de su sistema fue de 69%, esto a causa de la variabilidad en su conductividad térmica, de la misma manera el modelo de CytoCells tiene una precisión que oscila entre 50% y el 84,61% también a causa de variabilidad en el tamaño de las células, de la tinción, del número de células dentro de una imagen y la distancia entre célula y célula.

IX. CONCLUSIONES

En los resultados, evidenciaron que se pudo identificar de forma precisa las células de la mucosa vaginal, que mostraron variaciones en sus características durante las diferentes etapas del ciclo estral.

Un elemento novedoso de este estudio fue el entrenamiento del modelo de inteligencia artificial, con la habilidad de clasificar las muestras citológicas con una precisión bastante aceptable. Este modelo, demostró ser una herramienta prometedora para automatizar los procesos de análisis de muestras, reduciendo el tiempo y la subjetividad.

Con la creación de una aplicación móvil, este modelo se puede usar de una manera mucho más fácil, rápida y lo hace accesible para los médicos veterinarios que no cuentan con la experiencia en los análisis citológicos de este tipo de imágenes.

En conclusión, este estudio logro con éxito caracterizar el perfil citológico de la mucosa vaginal con ayuda de un modelo de inteligencia artificial que muestra un gran potencial para su uso en las clínicas veterinarias. Los resultados presentados abren nuevas oportunidades para el diagnóstico de patologías en el ciclo estral y el perfeccionamiento de modelos y programas para llevar un control sobre la reproducción y mejorar el bienestar animal.

X. RECOMENDACIONES

Como primer punto, se recomienda considerar aumentar el tamaño de muestra, considerando otras especies como por ejemplo bovinos, caprino, ovinos y porcinos, debido a que un modelo como este puede ser clave para los veterinarios dedicados a la producción por lo que llevarían un control del ciclo estral mediante un registro donde se indique el mejor momento ya sea para la monta como para la aplicación de protocolos de inseminación artificial, como también saber si se presentan anomalía en el sistema reproductivo de los animales.

En lo que al desarrollo de modelos de inteligencia artificial concierne, se recomienda investigar sobre algoritmos más sofisticados para mejorar la caracterización de imágenes citológicas.

Es de suma importancia seguir explorando esta área de la tecnología para optimizar el uso de inteligencia artificial tanto en citología como en más ámbitos de la medicina veterinaria. Se debe desarrollar interfaces con un uso más ágil y fácil para los médicos. Al mismo tiempo es primordial que se regule el uso de IA abordando aspectos éticos dentro de la práctica médica, garantizando seguridad e integridad a los pacientes.

REFERENCIAS

1. Rashid R, Bhat M, Dogra P, Sheikh A, Bhagat R, Ali A, et al. Exfoliative Vaginal Cytology (EVC) as a tool for determining breeding time in the bitch a case study. *Journal of Entomology and Zoology Studies* 2. 2017; 5(6).
2. Chitrang SHAH LBBV,VKSKNGJ,JPRRUBSRsMJ. Influence of estrous stages on electrocardiography, clinical pathology and ovarian weight of experimental beagle dogs: a retrospective analysis. *Interdisciplinary Toxicology*. 2019 ; 12(3).
3. Butinar J, Mujagic E, Galac S. THE OESTRUS CYCLE IN THE BITCH. *THE SCIENTIFIC JOURNAL OF THE VETERINARY FACULTY UNIVERSITY OF LJUBLJANA*. 2004; 41(1).
4. Bellamy J. Artificial intelligence in veterinary medicine requires regulation. *The Canadian Veterinary Journal*. 2023; 64(10).
5. Pereira A, Gonçalo P, Leite P, Ribeiro A, Alves S, Colaço B, et al. Artificial Intelligence in Veterinary Imaging: An Overview. *Veterinary Sciences*. 2023; 10(320).
6. Appleby R, Basran P. Artificial intelligence in veterinary medicine. *AVMA Publications*. 2022; 260(8).
7. Andrews C, Bullock L, Dennison T, Elder J, Mitchell A, Rivenbank M, et al. Mobile Technology in Veterinary Clinical Medicine. *Journal of Veterinary Medicine and Research*. 2015.
8. Rowe E, Reece W. *Functional Anatomy and Physiology of Domestic Animals*. Quinta ed.: Wiley-Blackwell; 2017.
9. Hermanson J, de Lahunta A, Evans H. *Anatomy of the Dog*. Quinta ed. St. Louis: Elsevier; 2020.
- 1 Momont H. MSD Manual. [Online]; 2022. Acceso 18 de Diciembre de 2023. Disponible en:
0. <https://www.msdvetmanual.com/dog-owners/reproductive-disorders-of-dogs/the-gonads-and-genital-tract-of-dogs#v3206139>.
- 1 Capello M, Aspinall V. *Introduction to Veterinary Anatomy and Physiology Textbook*. Tercera ed.: Elsevier; 2015.
- 1 Budras K, McCarthy P, Fricke W, Richter R. *Anatomy of the Dog*. Quinta ed. Budras K, editor. Hannover: Schlütersche Verlagsgesellschaft mbH & Co. KG; 2007.
- 1 Dyce KM, Sack WO, Wensing CJG. *TEXTBOOK OF VETERINARY ANATOMY*. Cuarto ed. St. Louis: Saunders Elsevier ; 2010.
- 1 Verin R, Cian F, Stewart J, Binanti D, MacNeill A, Piviani M, et al. Canine Clitoral Carcinoma: A
4. Clinical, Cytologic, Histopathologic, Immunohistochemical, and Ultrastructural Study. *Veterinary Pathology*. 2018; 55(4).
- 1 Klein B. *Cunningham's Textbook of Veterinary Physiology*. Sexta ed. Barcelona: Elsevier; 2020.
5.

- 1 Matamoros R, Salinas P. Fundamentos de Fisiología y Endocrinología reproductiva en animales 6. domésticos. Primera ed. Editores R, editor. Santiago: Universidad Santo Tomás; 2017.
- 1 Cordova C. Relación de la citología vaginal con el ciclo estral de la perra doméstica (Canis 7. familiaris). Tesis para obtener el título profesional de Médico Veterinario Zootecnista.
- 1 Concannon P, Castracane V, Temple M, Montanez A. Endocrine control of ovarian function in 8. dogs and other carnivores. Anim. Reprod. 2009; 6(1).
- 1 UNIVERSIDAD NACIONAL DEL LITORAL. Citología Vaginal. Trabajo Practico. 9.
- 2 Long S. Veterinary Genetics and Reproductive Physiology. Primera ed.: Elseiver; 2006. 0.
- 2 Lopate C. Reproductive Physiology of Canine Pregnancy and Partuition and Conditions of 1. Periparturient Period. En Lopate C, editor. Management of Pregnant and Neonatal Dog, Cats and Exotic Pets. Hoboken: John Wiley & Sons, Inc.; 2012. p. 25-41.
- 2 Stornelli MA, Luzbel R. Manual de Reproducción de animales de producción y compañía. Primera 2. ed. La Plata: Editorial de la Universidad Nacional de La Plata (EDULP); 2016.
- 2 Narvæz F. Identificación de hembras caninas domésticas en estro medianre la observación de 3. cristalización de la saliva como método diagnostico complementario comparado con citología vaginal. Trabajo de Investigación.
- 2 Echeverria J. Aspectos farmacologicos en el manejo reproductivo de la perra. Revisión 4. Bibliografica. REDVET. 2005; 6(3).
- 2 Concannon P. Reproductive cycles of the domestic bitch. Animal Reproduction Science. 2011; 5. 124(3-4).
- 2 Aspinall V. Reproductive system of the dog and cat- Part3. Reproductive physiology of the bitch. 6. Veterinary Nursing Journal. 2011; 26(5).
- 2 Aspinall V. Anatomy and Physiology of the Dog and Cat 10. The Female Reproductive System. 7. Veterinary Nursing Journal. 2004; 19(5).
- 2 Martínez E. Atlas de coitología clínica del perro y gato. Primera ed. Zaragoza: Grupo Asis 8. Biomedía S.L.; 2008.
- 2 Sharkey L, Radin J, Seelig D. Veterinary Cytology. Primera ed. Hoboken: John Wiley & Sons, Inc.; 9. 2021.
- 3 Davidson A. Clinician's Brief. [Online].; 2015. Acceso 29 de Diciembre de 2023. Disponible en: 0. <https://assets.ctfassets.net/4dmg311sxd6g/5pEz7njXptk0BTVReXAIIB/9341b2476352002efcf40f9404e90a8e/determining-canine-estrus-via-vaginal-cytology-22991-article.pdf>.
- 3 Alcila V, Serrano C, Hernandez M, Meza L. Estandarización de la citología vaginal exfoliativa 1. correlacionando los niveles séricos de progesterona en perras durante la peri-ovulación. RE V I S T A S P E I D O M U S. 2005; 1(2).

3 Reckers F, Klopfleisch R, Belik V, Artl S. Canine Vaginal Cytology: A Revised Definition of Exfoliated
2. Vaginal Cells. *Frontiers in Veterinary Science*. 2022; 9.

3 Root M. Vaginal Cytology in the Bitch and Queen. En Sharkley L, Radin J, Seelig D. *Veterinary
3. Cytology*.: Wiley-Blackwell; 2020. p. 552-557.

3 Stornelli MA, Savignone C, Tittarelli C, Stornelli M. *Citología Vaginal en caninos: Metodología y
4. Aplicaciones Clínicas*. Revisión.

3 Rosas J. Tinciones: Diff-Quick, Giemsa y Wright. Trabajo.
5.

3 Carrasco C. ESTUDIO COMPARATIVO DE CUATRO MÉTODOS DE COLORACIÓN (Azul de metileno,
6. Giemsa, Diff Quick y Papanicolaou) USADOS EN COLPOCITOGRAMAS CANINOS PARA VALORAR
CAMBIOS CITOLÓGICOS DURANTE EL ESTRO EN PERRAS Y SU APLICACIÓN EN EL DIAGNÓSTICO
DE NEOPLASIAS VAGINAL. Tesis.

3 Virbac. Atlas de Citología Vaginal. Folleto promocional.
7.

3 Stornelli MA, Luzbel R. Atlas de Reproducción de animales de producción y compañía. Primera
8. ed. La Plata: Editorial de la Universidad de La Plata; 2017.

3 Kumar K, Sengupta D, Sheetal S, Kumar A. Vaginal cytology: Method for detection of estrus in
9. canine. *The Pharma Innovation Journal*. 2023; 12(3).

4 Antonov AL. Application of exfoliative vaginal cytology in clinical canine reproduction. *Bulgarian
0. Journal of Veterinary Medicine*. 2017; 20(3).

4 Chiliquinga M. Hallazgos citológicos en mucosa vaginal de perras atendidas en centros
1. veterinarios de Guayaquil. Trabajo de titulación.

4 Escobedo W. DIAGNÓSTICO DEL ESTRO POR MEDIO DE CITOLOGÍA VAGINAL EN PERRAS. Tesis de
2. grado.

4 Gomes V. MSD Manual. [Online] Acceso 4 de Enero de 2024. Disponible en:
3. [https://www.msdsmanual.com/multimedia/image/exfoliative-vaginal-cytology-estrous-cycle-
dog](https://www.msdsmanual.com/multimedia/image/exfoliative-vaginal-cytology-estrous-cycle-dog).

4 Zohuri B, Behgounia F. Application of artificial intelligence driving nano-based drug delivery
4. system. En Philip A, Shahiwala A, Rashid M, Faiyazuddin M, editores. *A Handbook of Artificial
Intelligence in Drug Delivery*.: Academic Press; 2023. p. 145-212.

4 Saleh Z. Artificial Intelligence Definition, Ethics and Standards. *Journal of Artificial Intelligence*.
5. 2019.

4 Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *Minimally Invasive Therapy &
6. Allied Technologies*. 2019.

4 Basran P, Appleby R. The unmet potential of artificial intelligence in veterinary medicine. *AVMA
7. Publications*. 2022; 83(5).

- 4 Hennessey E, DiFazio M, Hennessey R, Cassel N. Artificial Intelligence in veterinary diagnostic 8. imaging: A literature review. Veterinary Radiology Ultrasound. 2022.
- 4 Hao J, Ho Kam T. Machine Learning Made Easy: A Review of Scikit-learn Package in Python 9. Programming Language. Journal of Educational and Behavioral Statistics. 2019; 20(10).
- 5 Hespel A, Zhang Y, Basran P. Artificial Intelligence 101 for veterinary diagnostic imaging. Vet 0. Radiol Ultrasound. 2022; 63(1).
- 5 Campbell S. Python Tutorial for Beginners. [Online]; 2024. Acceso 14 de Febrerode 2024.
1. Disponible en: <https://www.guru99.com/python-tutorials.html#:~:text=Python%20is%20an%20object%2Doriented,to%20C%20or%20C%2B%2B.>
- 5 Phumeejanya S. Academia. [Online].; 2017. Acceso 10 de Febrero de 2024. Disponible en:
2. https://www.academia.edu/41178445/Summary_Python_language.
- 5 Gallagher J. Roboflow. [Online]; 2023. Acceso 06 de Juniode 2024. Disponible en:
3. [https://blog.roboflow.com/labelme/.](https://blog.roboflow.com/labelme/)
- 5 Russel B, Torralba A, K. M, W. F. LabelMe: A Database and Web-Based Tool for Image Annotation.
4. International Journal of Computer Vision. 2008; 77.
- 5 Supervisely. Supervisely. [Online] Acceso 20 de Julio de 2024. Disponible en:
5. [https://supervisely.com/.](https://supervisely.com/)
- 5 Uguz S. Deep learning-based software for detecting population density of Antarctic birds.
6. Computer Science Journal of Moldova. 2023; 31(2).
- 5 KeyLabs. KeyLabs. [Online]; 2023. Acceso 20 de Juniode 2024. Disponible en:
7. [https://keylabs.ai/blog/under-the-hood-yolov8-architecture-explained/.](https://keylabs.ai/blog/under-the-hood-yolov8-architecture-explained/)
- 5 Hussain M. YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital
8. Manufacturing and Industrial Defect Detection. Machines. 2023; 11(7).
- 5 Krishnakumar M. Weights & Biases. [Online]; 2024. Acceso 30 de Juniode 2024. Disponible en:
9. <https://wandb.ai/mukilan/wildlife-yolov8/reports/A-Gentle-Introduction-to-YOLOv8--Vmlldzo0MDU5NDA2.>
- 6 Jocher G, Chaurasia A. Ultralytics YOLOv8. [Online]; 2024. Acceso 15 de Febrerode 2024.
0. Disponible en: <https://docs.ultralytics.com/es#yolo-licenses-how-is-ultralytics-yolo-licensed.>
- 6 Zafar , Sohaib. Medium. [Online]; 2023. Acceso 15 de Febrerode 2024. Disponible en:
1. <https://medium.com/@sohaib.zafar522/unleashing-the-power-of-yolo-v8-a-breakdown-of-its-working-principle-and-evolution-14a98d1feedc.>
- 6 John Snow Labs. John Snow Labs. [Online]; 2023. Acceso 24 de Juniode 2024. Disponible en:
2. https://sparknlp.org/api/python/third_party/Comet.html#comet-a-meta-machine-learning-platform.

- 6 Jocher G, Chaurasia A, Vina A. Ultralytics. [Online]; 2023. Acceso 03 de Juliodo 2024. Disponible 3. en: <https://docs.ultralytics.com/integrations/comet/#how-do-i-view-detailed-metrics-and-visualizations-of-my-yolov8-training-on-comet-ml>.
- 6 Comet. Comet. [Online]; 2023. Acceso 03 de Juliodo 2024. Disponible en:
4. <https://www.comet.com/site/>.
- 6 Faizan M. Medium. [Online]; 2022. Acceso 15 de Juliodo 2024. Disponible en:
5. <https://medium.com/red-buffer/roboflow-d4e8c4b52515>.
- 6 Analytics Indian Magazine. AIM. [Online] Acceso 15 de Juliodo 2024. Disponible en:
6. <https://analyticsindiamag.com/ai-mysteries/step-by-step-guide-to-object-detection-using-roboflow/>.
- 6 Gallagher J. Roboflow. [Online]; 2023. Acceso 25 de Febrerode 2024. Disponible en:
7. <https://blog.roboflow.com/data-augmentation/>.
- 6 Bouhali O, Bensmail H, Sheharyar A, David F, Johnson J. A Review of Radiomics and Artificial
8. Intelligence and Their Application in Veterinary Diagnostic Imaging. Vet. Sci.. 2022; 9(11).
- 6 Wolcott N, Kevin K, Raimond G, Hodges T, Shansky R, Galea L, et al. Automated classification of
9. estrous stage in rodents using deep learning. Scientific Reports. 2022; 12.
- 7 Kim E, Fishetti J, Sreentharan P, Weltman J, Fox P. Comparison of artificial intelligence to the
0. veterinary radiologist's diagnosis of canine cardiogenic pulmonary edema. Veterinary Radiology
& Ultrasound. 2022.
- 7 Dank G, Buber T, Rice A, Kraicer N, Hanel E, Shasha T, et al. Training and validation of a novel non-
1. invasive imaging system for ruling out malignancy in canine subcutaneous and cutaneous masses
using machine learning in 664 masses. Front. Vet. Sci. 2023; 10.
- 7 Haenlein M, Kaplan A. A Brief History of Artificial Intelligence: On the Past, Present, and Future of
2. Artificial Intelligence. California Management Review. 2019; 61(4).
- 7 Moxon R, Copley D, England G. Quality assurance of canine vaginal cytology: A preliminary study.
3. Theriogenology. 2010; 74(3).

ANEXOS

Ilustración 22 Toma de muestra



Ilustración 23 Toma de muestra



Ilustración 25 Observación de las muestras del microscopio



Ilustración 24 Toma de imágenes

