ACTUM FORENSE
IN DUBIO PRO SCIENTIA
ISSN 3101-4631

Vol. 2 · Núm. 1 · Año 2026

Métodos y técnicas actuales en el tanatocronodiagnóstico: de la tanatoquímica a la integración mediante inteligencia artificial

mercedes.alvarez@actumforense.es
ORCID: 0009-0006-4523-2210

Autores: Aleixandre Díez, Á.[1], Ferrer Gómez, M. C.[2] y Álvarez Seguí, M.[3]

[1] Médico Forense. Instituto de Medicina Legal y Ciencias Forenses de Valencia.
[2] Médico Forense. Jefa del Servicio de Clínica. Instituto de Medicina Legal y Ciencias Forenses de Valencia. Criminóloga.
[3] Médico Forense. Jefa del Servicio de Laboratorio. Instituto de Medicina Legal y Ciencias Forenses de Valencia. Criminóloga.

Historia del artículo:
Recibido: 30/12/2025
Corregido: 28/10/2026
Aceptado: 01/11/2026
Publicado: 01/11/2026

Tipo de trabajo:
Revisión narrativa

Contribución de Autoría:
Autor 1 y 2:
Conceptualización, metodología y redacción.
Autor 3:
Conceptualización, metodología y revisión.

Conflicto de intereses:
Los autores declaran no tener ningún tipo de conflicto de intereses.

Resumen

La estimación del intervalo *post mortem* (IPM) sigue siendo una de las tareas más difíciles de la medicina forense. Esta revisión narrativa analiza el rendimiento documentado de los métodos actuales —el nomograma de Henssge y el método compuesto, la tanatoquímica del humor vítreo, el tanatomicrobioma y la metabolómica— y el papel que empieza a desempeñar el aprendizaje automático. La validación del método de Henssge en 76 fallecidos con hora de muerte conocida mostró un acuerdo global del 36,8 % con su intervalo de predicción al 95 %. El potasio vítreo aumenta de forma no lineal y su variabilidad depende de la edad y de la temperatura ambiente, y los modelos microbianos alcanzan, sobre todo en estudios con animales, errores de pocos días a lo largo de semanas. El resultado más sólido procede de la metabolómica de sangre femoral: una red neuronal entrenada con 4876 casos estimó el IPM con un error absoluto medio de 1,45 días, y de 1,78 días en una cohorte externa analizada en otra plataforma. Se discuten el ruido tafonómico, el sobreajuste y la validación externa como condiciones de fiabilidad, y la exigencia de transparencia que imponen los criterios Daubert, la valoración de la prueba pericial conforme a la sana crítica y el Reglamento europeo de inteligencia artificial. Se concluye que el aprendizaje automático puede ampliar la ventana útil de la datación, pero su uso pericial requiere validación multicéntrica, cuantificación del error y modelos cuyo razonamiento pueda explicarse ante el tribunal.

ACTUM FORENSE
IN DUBIO PRO SCIENTIA
ISSN 3101-4631

Vol. 2 · Núm. 1 · Año 2026

Fuentes de financiación: Los autores declaran la ausencia de financiación.

Cómo citar este artículo: Aleixandre Díez, Á., Ferrer Gómez, M. C. y Álvarez Seguí, M. (2026). Métodos y técnicas actuales en el tanatocronodiagnóstico: de la tanatoquímica a la integración mediante inteligencia artificial. *Actum Forense*.

Artículo de acceso abierto (open access), publicado bajo licencia Creative Commons Atribución-NoComercial-SinDerivadas 4.0 Internacional (CC BY-NC-ND 4.0).

Palabras clave: tanatocronodiagnóstico, intervalo *post mortem*, humor vítreo, tanatomicrobioma, metabolómica, aprendizaje automático, inteligencia artificial explicable, prueba pericial.

Abstract

Estimating the post-mortem interval (PMI) remains one of the most difficult tasks in forensic medicine. This narrative review examines the documented performance of current methods —Henssge's nomogram and the compound method, vitreous humour thanatochemistry, the thanatomicrobiome and metabolomics— and the emerging role of machine learning. A validation of the Henssge method in 76 decedents with known time of death showed an overall agreement of 36.8% with its 95% prediction interval. Vitreous potassium rises non-linearly and its variability depends on age and ambient temperature, while microbial models achieve, mainly in animal studies, errors of a few days over several weeks. The strongest evidence comes from femoral blood metabolomics: a neural network trained on 4,876 cases estimated the PMI with a mean absolute error of 1.45 days, and of 1.78 days in an external cohort analysed on a different platform. Taphonomic noise, overfitting and external validation are discussed as conditions of reliability, together with the transparency required by the Daubert criteria, by the free evaluation of expert evidence under Spanish procedural law and by the European Artificial Intelligence Act. We conclude that machine learning can extend the useful window of time-since-death estimation, but its forensic use requires multicentre validation, quantified error rates and models whose reasoning can be explained in court.

Keywords: time since death, post-mortem interval, vitreous humour, thanatomicrobiome, metabolomics, machine learning, explainable artificial intelligence, expert evidence.

Introducción

La determinación de la data de la muerte es una de las preguntas que con más frecuencia se plantean al médico forense y una de las de mayor trascendencia para la investigación criminal: delimita el momento probable de los hechos, permite contrastar coartadas y orienta la identificación (Madea, 2016). Durante décadas, la medicina legal se ha apoyado en la observación de los fenómenos cadavéricos —enfriamiento, livideces, rigidez, putrefacción— y en su cuantificación mediante modelos físicos, cuya precisión disminuye a medida que se alarga el intervalo y que dependen en gran medida de las condiciones ambientales (Henssge y Madea, 2004; Madea, 2016).

La necesidad de dotar al dictamen de mayor objetividad ha impulsado la búsqueda

de marcadores químicos y biológicos menos dependientes de la temperatura. La limitación estructural de los métodos clásicos no es su antigüedad, sino precisamente esa dependencia térmica, que explica por qué el nomograma sigue siendo insustituible en la escena durante las primeras horas y, a la vez, insuficiente cuando el intervalo se prolonga. Sin embargo, ninguno de los métodos químicos ha conseguido todavía un lugar estable en la práctica diaria, en buena medida por la escasez de estudios de campo sobre su precisión (Madea, 2005).

En este contexto, la inteligencia artificial (IA), y en particular el aprendizaje automático (*machine learning*), permite analizar a la vez muchas variables y explorar relaciones no lineales entre ellas. Una revisión de alcance reciente constató, no obstante, que sus aplicaciones en medicina forense siguen sobre todo en fase de investigación y desarrollo (Tournois et al., 2024), y desde la propia disciplina se ha reclamado una orientación jurídica específica para su uso (Ondruschka et al., 2024). Su utilidad pericial debe establecerse mediante una validación adecuada, la cuantificación del error y la delimitación de sus condiciones de aplicación.

El objetivo de este trabajo es revisar el rendimiento documentado de los principales métodos de tanatocronodiagnóstico, desde el nomograma de Henssge hasta los modelos de aprendizaje automático aplicados a la tanatoquímica, al tanatomicrobioma y a la metabolómica, y analizar las condiciones técnicas y jurídicas que deben cumplir estos modelos para fundamentar un dictamen pericial.

Metodología

Se ha realizado una revisión narrativa de la literatura científica con enfoque descriptivo-comparativo. La búsqueda se efectuó en PubMed y Scopus combinando los descriptores «postmortem interval», «time since death», «machine learning», «vitreous humor», «thanatomicrobiome», «metabolomics» y «Daubert», y se completó con la revisión de las referencias de los trabajos seleccionados. Se priorizaron los estudios publicados entre 2004 y 2026, sin excluir las publicaciones originales de los métodos de referencia (Henssge, 1988).

Se seleccionaron estudios originales y revisiones que contrastaran los métodos clásicos con técnicas bioquímicas, moleculares o computacionales y que aportaran una medida cuantificada del rendimiento: grado de acuerdo con la hora real de la muerte, error absoluto medio, varianza explicada o exactitud de clasificación. En los modelos de aprendizaje automático se valoró, además, si el rendimiento se había comprobado mediante validación cruzada o en una muestra externa independiente. Se excluyeron las fuentes divulgativas y los trabajos sin descripción metodológica suficiente.

Los datos se sistematizaron en una matriz de análisis de diseño propio que recoge, para cada método, la población estudiada (cadáveres humanos, modelos animales o datos sintéticos), la ventana temporal y el rendimiento documentado; la tabla 1 resume esa matriz. Al tratarse de una revisión narrativa, no se ha realizado un metaanálisis ni una evaluación formal del riesgo de sesgo, y los valores se citan tal como los publican los estudios originales.

Resultados

La estimación del IPM ha evolucionado desde los modelos termodinámicos hacia el análisis de datos de alta dimensión, impulsada por las limitaciones demostradas de los métodos físicos y por la maduración de alternativas bioquímicas y moleculares. La tabla 1 sintetiza los resultados de la matriz de análisis descrita en la metodología.

El nomograma de Henssge: utilidad operativa y límites estructurales

El nomograma de Henssge se basa en un modelo de enfriamiento rectal de doble exponencial y permite obtener, con una sola medición de la temperatura rectal, una estimación inmediata en la escena, sin cálculos adicionales (Henssge, 1988). Es el método de referencia de la fase temprana y se combina con criterios no térmicos —excitabilidad eléctrica y mecánica del músculo, excitabilidad farmacológica del iris, rigidez y livideces— en el denominado método compuesto, que reduce el margen de error (Henssge y Madea, 2004; Madea, 2016). Su debilidad estructural es la dependencia térmica: el modelo presupone una temperatura ambiente estable y unas condiciones de enfriamiento que, en la práctica, se alteran con los cambios de temperatura del entorno, la ropa, la cobertura del cuerpo o el contacto con superficies frías (Henssge y Madea, 2004).

La evidencia reciente ha cuantificado esta limitación. En una validación sobre 76 fallecidos con hora de muerte conocida, el acuerdo global entre la hora real y el intervalo de predicción al 95 % del método compuesto fue del 36,8 % (IC 95 %: 26,1-48,7): del 61,9 % en los cadáveres conservados a temperatura ambiente y del 27,3 % en los refrigerados; el índice de masa corporal y la superficie corporal influyeron en la probabilidad de acuerdo (Heinrich et al., 2025). Un estudio experimental anterior, que comparó el nomograma con las curvas de enfriamiento registradas en condiciones controladas en 84 fallecidos, registró violaciones del intervalo de confianza al 95 % en el 57,1 % de los casos; sus autores concluyeron que la validez de esos intervalos es problemática, que deben interpretarse con cautela antes de usarlos para sostener o refutar una coartada y que el método

sobreestima de forma sistemática el IPM en cuerpos de gran masa y superficie corporal (Hubig et al., 2015).

Dani et al. (2023) aplicaron máquinas de vectores de soporte (SVM) y árboles de regresión a 3000 casos sintéticos generados con la propia fórmula de Henssge y obtuvieron errores del orden de ±20 minutos. El resultado muestra que el aprendizaje automático puede reproducir con gran exactitud la relación que describe la fórmula, pero no acredita una precisión equivalente frente a la hora real de la muerte en cadáveres ni corrige los supuestos físicos del modelo original: su aplicación pericial exige validación empírica.

Tanatoquímica del humor vítreo: potasio e hipoxantina

Para cubrir el intervalo intermedio, en el que el método térmico pierde fiabilidad, la tanatoquímica se ha centrado en el humor vítreo, un compartimento aislado y protegido en el que los cambios autolíticos progresan más despacio que en la sangre o en el líquido cefalorraquídeo (Madea, 2005). El marcador más estudiado es el potasio (K^+), cuya concentración aumenta tras la muerte por difusión desde las células que rodean el vítreo (Li et al., 2018; Zilg et al., 2015). Las ecuaciones clásicas suponen un aumento lineal, pero en una serie de 462 casos con IPM conocido, de 2 horas a 17 días, el ascenso siguió una curva no lineal; la edad explicó un 16 % de la variabilidad y la temperatura ambiente un 5 %, y la corrección por ambas variables estrechó los intervalos de confianza en todo el rango estudiado (Zilg et al., 2015). El potasio vítreo es, por tanto, mucho menos sensible a la temperatura que el enfriamiento corporal, aunque no independiente de ella.

Aun así, la estimación basada solo en el K^+ es insuficiente para el contexto pericial: a los errores preanalíticos, analíticos y posanalíticos de la determinación se suma la variabilidad estadística de la ecuación de regresión, de modo que cualquier error se amplifica en la estimación final (McCleskey et al., 2016). La hipoxantina (Hx), producto de la degradación de las purinas en condiciones de hipoxia, se ha propuesto como marcador complementario: combinada con el K^+ y con la temperatura ambiente, permite estimar el tiempo transcurrido con una precisión relativamente alta (Rognum et al., 2016). En una serie española, considerar la causa de la muerte mejoró el ajuste de las ecuaciones: en los ahorcamientos, el coeficiente de determinación pasó de 0,688 a 0,818 para el K^+ y de 0,518 a 0,757 para la Hx (Muñoz Barús et al., 2002). En 70 autopsias con IPM de hasta 60 horas, la ecuación más exacta fue la que combinaba K^+ e Hx con la puntuación de las livideces, la rigidez y la opacidad corneal, y los fenómenos físicos resultaron más útiles que la tanatoquímica aislada en ese rango (Salam et

al., 2012).

La dirección más prometedora es el análisis simultáneo de varios constituyentes (Li et al., 2018). En humor vítreo ovino, un modelo multivariante de metabolómica por resonancia magnética nuclear de protón, validado en una muestra independiente, obtuvo errores de 6,9 horas por debajo de las 24 horas, de 7,4 horas entre 24 y 48 horas y de 10,3 horas por encima de ese límite; superó al potasio hasta las 48 horas, y la combinación de ambos fue mejor en los intervalos más largos (Locci et al., 2023). Se trata, no obstante, de una prueba de concepto en un modelo animal.

El tanatomicrobioma

El tanatomicrobioma —las comunidades microbianas que colonizan los órganos internos y los orificios tras la muerte— ha abierto una vía de datación para las fases avanzadas, cuando la tanatoquímica pierde capacidad predictiva. Órganos que en vida se consideran estériles, como el bazo, el hígado, el corazón o el cerebro, presentan después de la muerte firmas microbianas propias (Can et al., 2014). En 27 cadáveres de casos judiciales con IPM de 3,5 a 240 horas, la secuenciación del gen del ARN ribosómico 16S mostró cambios dependientes del tiempo, del órgano y del sexo (Javan et al., 2016); según la síntesis de Moitas et al. (2024), el análisis a nivel de familia y de género explicaba alrededor del 21 % de la varianza en los modelos de correlación con el IPM, frente al 65 % a nivel de especie, con miembros de los géneros *Clostridium* y *Prevotella* asociados a distintos periodos de la descomposición.

La sucesión microbiana es, además, reproducible. En un modelo murino, los cambios de la comunidad permitieron estimar el IPM con un error aproximado de 3 días a lo largo de 48 días (Metcalf et al., 2013), y en cadáveres de ratón y humanos depositados sobre distintos suelos surgió, en plazos predecibles, una red de microorganismos descomponedores procedentes sobre todo del suelo (Metcalf et al., 2016). Las técnicas de secuenciación han pasado del gen 16S a la metagenómica y, recientemente, a la 2bRAD-M, que ha permitido describir la sucesión en siete tejidos humanos —corazón, hígado, bazo, pulmón, riñón, músculo de la pantorrilla e intestino—, con predominio de Proteobacteria en las fases iniciales y de Firmicutes en las tardías, y con diferencias en el hígado y el bazo entre cadáveres congelados y no congelados (Huang et al., 2026).

El aprendizaje automático es el instrumento habitual para convertir estos perfiles en estimaciones (Wang et al., 2022; Wu et al., 2024). Se han desarrollado modelos de bosques aleatorios (*random forest*) con la microbiota del apéndice y del colon transverso de cadáveres con IPM de 5 a 192 horas (Hu et al., 2021) y con la

microbiota oral y nasal, con un error absoluto medio de 2,16 días en el conjunto de entrenamiento y de 5,14 días en el de prueba (Chen et al., 2025). Con muestras de suelo y de piel, los modelos más exactos se obtuvieron con el gen 16S al nivel taxonómico de filo (Belk et al., 2018), y un regresor de k vecinos más próximos entrenado con muestras nasales y del conducto auditivo predijo el IPM con un error medio de ±55 grados-día acumulados (Johnson et al., 2016). En frío extremo, un modelo animal que integraba datos microbianos y ambientales —espesor de la nieve, temperatura exterior— alcanzó un error absoluto medio de 1,36 semanas a lo largo de seis meses de invierno (Iancu et al., 2024). La revisión de Wu et al. (2024) recoge, además, un modelo en dos etapas, desarrollado en ratas, que clasifica primero los casos en grupos de 0-7 y de 9-30 días mediante varios algoritmos y aplica después una regresión de bosques aleatorios. Conviene recordar que clasificar en grupos temporales y estimar un IPM continuo son tareas distintas, y que buena parte de estos resultados procede de modelos animales (Dong et al., 2019; Y e Isukapatla, 2026).

La traslación medicolegal se enfrenta a limitaciones aún no resueltas. Las comunidades microbianas dependen del entorno, de la causa de la muerte y del estado de salud previo del fallecido, y la variabilidad interindividual del microbioma —influida, entre otros factores, por la dieta— puede afectar a la interpretación (Moitas et al., 2024; Y e Isukapatla, 2026). Faltan, además, flujos de trabajo armonizados de extracción y secuenciación del ADN y puntos de muestreo estandarizados que permitan comparar los resultados de distintos grupos (Cláudia-Ferreira et al., 2023; Tozzo et al., 2022). La investigación futura debe orientarse a identificar biomarcadores estables dentro de los filos dominantes, Bacillota y Pseudomonadota, y a constituir bancos de datos microbianos forenses de referencia (Cláudia-Ferreira et al., 2023).

En los intervalos muy prolongados, y en particular en los restos esqueléticos, la situación es todavía más precaria: la única técnica de datación plenamente reconocida es la medición del carbono 14 y no existe un método preciso y seguro para el IPM tardío (Franceschetti et al., 2023).

Metabolómica de sangre y de órganos

El resultado más sólido hasta la fecha procede de la metabolómica. Magnusson et al. (2026) utilizaron los datos de los cribados toxicológicos rutinarios de sangre femoral de 4876 fallecidos con IPM conocido, de 1 a 67 días, y desarrollaron una red neuronal que predijo el IPM con un error absoluto medio de 1,45 días (mediana de 1,03 días) en casos no vistos por el modelo, por delante de otras seis arquitecturas de aprendizaje automático. Como el 97 % de los casos tenía un IPM de entre 1 y 13 días, el rendimiento principal se informa para ese rango. Aplicado

ACTUM FORENSE
IN DUBIO PRO SCIENTIA
ISSN 3101-4631
Vol. 2 · Núm. 1 · Año 2026

sin reentrenamiento a 512 casos de otro año, analizados en otra plataforma de espectrometría de masas, el modelo mantuvo un error absoluto medio de 1,78 días (mediana de 1,29). En modelos animales, la combinación de los perfiles metabolómicos de cuatro órganos de rata mediante técnicas de aprendizaje por ensamblado (*stacking*) alcanzó una exactitud de clasificación del 93 % (Lu et al., 2023).

Tabla 1

Comparativa de métodos de tanatocronodiagnóstico: población, ventana temporal y rendimiento documentado

Método o biomarcador	Población y ventana estudiada	Rendimiento documentado	Fuente
Nomograma de Henssge (método compuesto)	76 fallecidos; fase temprana	Acuerdo con el intervalo de predicción al 95 %: 36,8 % global; 61,9 % en cadáveres a temperatura ambiente y 27,3 % en refrigerados	Heinrich et al. (2025)
Nomograma de Henssge	84 fallecidos; enfriamiento registrado en condiciones controladas	Violaciones del intervalo de confianza al 95 % en el 57,1 % de los casos; sobreestimación sistemática en cuerpos de gran masa y superficie	Hubig et al. (2015)
Fórmula de Henssge + aprendizaje automático (SVM, árboles de regresión)	3000 casos sintéticos	Error aproximado de ±20 min frente a la propia fórmula; sin validación en cadáveres	Dani et al. (2023)
Potasio vítreo (K^+)	462 casos; 2 h a 17 días	Ascenso no lineal; la edad explica el 16 % y la temperatura el 5 % de la variabilidad; corregir por ambas estrecha los intervalos	Zilg et al. (2015)
K^+ e hipoxantina (Hx) vítreos	132 casos (Rognum); serie de autopsias de Santiago de Compostela	Precisión relativamente alta con K^+, Hx y temperatura; R^2 de 0,688 (K^+) y 0,518 (Hx), y de 0,818 y 0,757 en ahorcamientos	Rognum et al. (2016); Muñoz Barús et al. (2002)
Metabolómica del humor vítreo (^{1}H-RMN)	Modelo ovino; 6 a 86 h	Error de 6,9 h (< 24 h), 7,4 h (24-48 h) y 10,3 h (> 48 h) en validación independiente	Locci et al. (2023)
Tanatomicrobioma de órganos internos (ARNr 16S)	27 cadáveres; 3,5 a 240 h	Varianza explicada del 21 % a nivel de familia y género y del 65 % a nivel de especie	Javan et al. (2016); Moitas et al. (2024)

ACTUM FORENSE
IN DUBIO PRO SCIENTIA
ISSN 3101-4631
Vol. 2 · Núm. 1 · Año 2026

Método o biomarcador	Población y ventana estudiada	Rendimiento documentado	Fuente
Microbiota oral y nasal + bosques aleatorios	34 cadáveres	Error absoluto medio de 2,16 días (entrenamiento) y 5,14 días (prueba)	Chen et al. (2025)
Microbioma nasal + variables ambientales + bosques aleatorios	Modelo animal; frío extremo, 23 semanas	Error absoluto medio de 1,36 semanas (R^2 = 0,91)	Iancu et al. (2024)
Metabolómica de sangre femoral + red neuronal	4876 casos; 1 a 67 días (97 % entre 1 y 13)	Error absoluto medio de 1,45 días (mediana 1,03); 1,78 días (mediana 1,29) en 512 casos externos	Magnusson et al. (2026)

Nota. Los valores son los publicados en los estudios originales; no proceden de un metaanálisis y no son directamente comparables entre sí, porque difieren la población, la ventana temporal y la medida de rendimiento. SVM: máquinas de vectores de soporte; ^{1}H-RMN: resonancia magnética nuclear de protón.

Discusión

El valor diferencial del aprendizaje automático reside en su capacidad para integrar en un mismo modelo variables de distinta naturaleza. Los ejemplos disponibles son todavía parciales —varios órganos en un mismo modelo (Lu et al., 2023), datos microbianos y ambientales (Iancu et al., 2024) o cientos de metabolitos a la vez (Magnusson et al., 2026)—, pero apuntan hacia modelos que combinen señales metabolómicas, microbiológicas, tanatoquímicas y ambientales, algo que las fórmulas termodinámicas no pueden hacer.

Metabolómica y aprendizaje automático: la ventana de los trece días

El estudio de Magnusson et al. (2026) es, por su tamaño y por su validación externa, el avance más relevante de los últimos años. Sus autores recuerdan que la temperatura rectal y el potasio vítreo solo ofrecen estimaciones fiables durante los primeros 1-3 días; un error medio inferior a un día y medio entre 1 y 13 días desplaza de forma notable el límite práctico de la datación. Además, el método aprovecha muestras que ya se recogen en los cribados toxicológicos rutinarios, lo que facilitaría su incorporación a la práctica.

Este resultado debe tomarse como la referencia frente a la cual medir los avances posteriores, no como un estándar ya consolidado. Procede de un único sistema

medicolegal, el sueco; el error aumenta en los extremos del rango, y los autores reconocen como limitación importante la falta de documentación de las condiciones de transporte y almacenamiento, que impide calcular los grados-día acumulados. Además, algunos metabolitos varían a la vez con el IPM y con la causa de la muerte (Magnusson et al., 2026). El valor de estos modelos reside en identificar relaciones no lineales en la dinámica de los metabolitos —marcadores de degradación lipídica, disfunción mitocondrial y proteólisis— que las fórmulas termodinámicas no pueden recoger.

La traslación al contexto pericial exige trazabilidad analítica. Si los protocolos de muestreo, conservación o análisis difieren entre centros, el modelo puede aprender particularidades de la adquisición en lugar de procesos biológicos; los propios autores advierten de que los institutos forenses pueden seguir protocolos distintos y no recoger datos comparables, lo que limita la transferibilidad directa (Magnusson et al., 2026). La estandarización de los biomarcadores y de los procedimientos de recogida es, por ello, un requisito previo para comparar casos y laboratorios.

Gestión del ruido tafonómico: el criterio diferencial frente a los métodos clásicos

La robustez de cualquier modelo de IPM debe comprobarse frente al llamado ruido tafonómico: el conjunto de factores bióticos y abióticos que modifican la cinética de la descomposición. Son factores intrínsecos la edad, la masa y la superficie corporal, las enfermedades previas, la duración de la agonía o la causa de la muerte, y extrínsecos la temperatura ambiente, la humedad, el suelo o la actividad de la fauna necrófaga (Madea, 2016; Moitas et al., 2024). Son precisamente los factores que desajustan los modelos clásicos: la masa y la superficie corporal desplazan las estimaciones del nomograma (Heinrich et al., 2025; Hubig et al., 2015), y la edad y la temperatura, las del potasio vítreo (Zilg et al., 2015). Una fórmula lineal con una o dos variables no puede separarlos de la señal temporal; un modelo multivariante puede incorporarlos como variables explicativas, como muestra la mejora obtenida al añadir datos ambientales a los perfiles microbianos (Iancu et al., 2024).

Esta capacidad tiene un riesgo: el sobreajuste (*overfitting*), por el que el modelo memoriza particularidades de los datos de entrenamiento en lugar del patrón biológico. Para evitarlo se emplean técnicas de regularización —en el estudio de Magnusson et al. (2026), por ejemplo, la desactivación aleatoria de neuronas (*dropout*) en la red y una regresión LASSO ajustada mediante validación cruzada en cinco particiones— y, sobre todo, la validación en conjuntos de datos independientes del entrenamiento. La aplicación del modelo metabolómico a 512 casos de otro año y otra plataforma, con un error de 1,78 días y sin

reentrenamiento, es el tipo de prueba de validez externa que debería exigirse a cualquier modelo antes de su uso forense (Magnusson et al., 2026).

La evaluación del rendimiento no debe limitarse al error medio. Debe incluir la calibración de las probabilidades, la estabilidad de la contribución de cada variable entre escenarios distintos y la detección de la deriva de los datos cuando cambian los instrumentos o la población, aspectos que forman parte de la validación rigurosa en condiciones diversas que se reclama para estos modelos (Wu et al., 2024).

Admisibilidad judicial: inteligencia artificial explicable y criterios Daubert

La incorporación de modelos de aprendizaje profundo a la práctica pericial plantea un problema jurídico tanto como técnico: la opacidad algorítmica o «caja negra». La complejidad de estas arquitecturas puede impedir reconstruir el razonamiento que lleva a una estimación del IPM, y en el propio campo se reconoce que sus mecanismos internos siguen siendo a menudo opacos, cuando en el ámbito forense el fundamento de las conclusiones debe ser claro y justificable (Wu et al., 2024). A un tribunal no le basta con saber que el algoritmo es preciso: necesita saber por qué el modelo ha dado más peso a un metabolito, a un taxón bacteriano o a la concentración de potasio para fundamentar una fecha, y no a otros.

En el sistema federal estadounidense, la sentencia *Daubert* estableció que el juez debe valorar si el método pericial se ha sometido a prueba, si se ha revisado por pares y publicado, si tiene una tasa de error conocida o potencial y normas que controlen su aplicación, y si goza de aceptación general en la comunidad científica (*Daubert v. Merrell Dow Pharmaceuticals, Inc.*, 1993). Al aplicar estos criterios y los de la doctrina *Frye*, Meurs et al. (2019) concluyeron que ninguno de los biomarcadores bioquímicos del IPM bien estudiados, ni siquiera el potasio, que era el más completo, podía considerarse apto como prueba ante un tribunal, y que el 94 % de los marcadores propuestos estaba insuficientemente investigado. En España no rige un estándar de admisibilidad equivalente, pero el tribunal valora los dictámenes según las reglas de la sana crítica (artículo 348 de la Ley 1/2000, de Enjuiciamiento Civil) y, en el proceso penal, aprecia en conciencia la prueba practicada (artículo 741 de la Ley de Enjuiciamiento Criminal); en ambos casos, el perito ha de poder explicar y someter a contradicción el fundamento de su conclusión.

A este marco se suma el Reglamento (UE) 2024/1689 de inteligencia artificial, que considera de alto riesgo, entre otros, los sistemas destinados a evaluar la fiabilidad de las pruebas en la investigación o el enjuiciamiento de delitos y los destinados a asistir a las autoridades judiciales en la investigación e interpretación de los hechos

(Parlamento Europeo y Consejo de la Unión Europea, 2024, anexo III, puntos 6 y 8). Un sistema de estimación del IPM empleado en una investigación penal podría encajar en esos supuestos y quedaría sujeto, entre otras obligaciones, a requisitos de transparencia que permitan interpretar sus resultados y a una supervisión humana efectiva (artículos 13 y 14). Tras la modificación introducida por el Reglamento (UE) 2026/1744, esas obligaciones se aplican a los sistemas del anexo III a partir del 2 de diciembre de 2027 (Parlamento Europeo y Consejo de la Unión Europea, 2026).

La respuesta técnica a estas exigencias es la inteligencia artificial explicable (XAI), que debe permitir al perito identificar y comunicar qué variables concretas —niveles de metabolitos, taxones bacterianos, concentración de potasio, condiciones ambientales— han sustentado la estimación en cada caso. Para las decisiones de alto riesgo, como las judiciales, se ha defendido incluso que es preferible diseñar modelos interpretables desde el principio antes que explicar a posteriori una caja negra (Rudin, 2019). En cualquier caso, la transparencia convierte el algoritmo en un instrumento pericial auditable, cuya lógica puede examinarse, cuestionarse y refutarse en el juicio; sin ella, el uso de la IA en el tanatocronodiagnóstico carecería del fundamento necesario para ser aceptado como prueba pericial, por sólida que sea su precisión estadística (Ondruschka et al., 2024; Rudin, 2019).

Conclusiones

El tanatocronodiagnóstico atraviesa una fase de transición que responde a una necesidad científica documentada y no a una moda tecnológica. Los métodos termodinámicos, encabezados por el nomograma de Henssge y el método compuesto, conservan su valor como herramienta de respuesta inmediata en la escena, pero su dependencia térmica limita su fiabilidad incluso en las primeras horas —con un acuerdo del 36,8 % en una validación reciente— y la reduce todavía más en intervalos largos (Heinrich et al., 2025; Henssge y Madea, 2004). Su uso exclusivo como referencia pericial no es sostenible.

La tanatoquímica del humor vítreo amplía la ventana de datación si se corrigen factores como la edad y la temperatura y se combina el potasio con otros marcadores (Rognum et al., 2016; Zilg et al., 2015). El tanatomicrobioma ofrece una vía para las fases avanzadas, pero todavía depende en gran medida de modelos animales y carece de protocolos estandarizados. La metabolómica procesada con aprendizaje automático es hoy la alternativa con mejor respaldo empírico, con un error medio inferior a un día y medio entre 1 y 13 días y validación en una cohorte externa (Magnusson et al., 2026), aunque falta su confirmación multicéntrica.

La precisión estadística es condición necesaria, pero no suficiente, para la admisibilidad pericial. Un modelo incapaz de fundamentar su resultado en términos biológicos auditables no satisface los criterios Daubert ni resiste la valoración conforme a la sana crítica, y en la Unión Europea deberá cumplir además los requisitos de transparencia y supervisión humana de los sistemas de alto riesgo (Meurs et al., 2019; Parlamento Europeo y Consejo de la Unión Europea, 2024; Rudin, 2019). La inteligencia artificial explicable es, en consecuencia, tan necesaria como la mejora de la precisión.

Por último, ningún algoritmo sustituye al juicio medicolegal: por refinadas que lleguen a ser las estimaciones de laboratorio, la conclusión pericial sobre el IPM debe integrar los hallazgos de la escena, la información sobre la última vez que se vio con vida al fallecido y los resultados de la autopsia y de los análisis complementarios (McCleskey et al., 2016). Los modelos que gestionen el ruido tafonómico, garanticen la trazabilidad analítica y expliquen su razonamiento permitirán expresar la data de la muerte en rangos de probabilidad cuantificados, reproducibles y defendibles ante un tribunal.

Referencias bibliográficas

Belk, A., Xu, Z. Z., Carter, D. O., Lynne, A., Bucheli, S., Knight, R. y Metcalf, J. L. (2018). Microbiome data accurately predicts the postmortem interval using random forest regression models. *Genes, 9*(2), 104. https://doi.org/10.3390/genes9020104

Can, I., Javan, G. T., Pozhitkov, A. E. y Noble, P. A. (2014). Distinctive thanatomicrobiome signatures found in the blood and internal organs of humans. *Journal of Microbiological Methods, 106*, 1–7. https://doi.org/10.1016/j.mimet.2014.07.026

Chen, J., Wei, Q., Yang, F., Liu, Y., Zhao, Y., Zhang, H., Huang, X., Zeng, J., Wang, X. y Zhang, S. (2025). Unveiling the forensic potential of oral and nasal microbiota in post-mortem interval estimation. *International Journal of Molecular Sciences, 26*(7), 3432. https://doi.org/10.3390/ijms26073432

Cláudia-Ferreira, A., Barbosa, D. J., Saegeman, V., Fernández-Rodríguez, A., Dinis-Oliveira, R. J. y Freitas, A. R. (2023). The future is now: Unraveling the expanding potential of human (necro)microbiome in forensic investigations. *Microorganisms, 11*(10), 2509. https://doi.org/10.3390/microorganisms11102509

Dani, L. M., Tóth, D., Frigyik, A. B. y Kozma, Z. (2023). Beyond Henssge's formula: Using regression trees and a support vector machine for time of death estimation in forensic medicine. *Diagnostics, 13*(7), 1260. https://doi.org/10.3390/diagnostics13071260

Daubert v. Merrell Dow Pharmaceuticals, Inc., 509 U.S. 579 (1993).

Dong, K., Xin, Y., Cao, F., Huang, Z., Sun, J., Peng, M., Liu, W. y Shi, P. (2019). Succession of oral microbiota community as a tool to estimate postmortem interval. *Scientific Reports, 9*, 13063. https://doi.org/10.1038/s41598-019-49338-z

Franceschetti, L., Amadasi, A., Bugelli, V., Bolsi, G. y Tsokos, M. (2023). Estimation of late postmortem interval: Where do we stand? A literature review. *Biology, 12*(6), 783. https://doi.org/10.3390/biology12060783

Heinrich, F., Rimkus-Ebeling, F., Dietz, E., Raupach, T., Ondruschka, B. y Anders-Lohner, S. (2025). An assessment of the Henssge method for forensic death time estimation in the early post-mortem interval. *International Journal of Legal Medicine, 139*(1), 105–117. https://doi.org/10.1007/s00414-024-03338-5

Henssge, C. (1988). Death time estimation in case work. I. The rectal temperature time of death nomogram. *Forensic Science International, 38*(3–4), 209–236. https://doi.org/10.1016/0379-0738(88)90168-5

Henssge, C. y Madea, B. (2004). Estimation of the time since death in the early post-mortem period. *Forensic Science International, 144*(2–3), 167–175. https://doi.org/10.1016/j.forsciint.2004.04.051

Hu, L., Xing, Y., Jiang, P., Gan, L., Zhao, F., Peng, W., Li, W., Tong, Y. y Deng, S. (2021). Predicting the postmortem interval using human intestinal microbiome data and random forest algorithm. *Science & Justice, 61*(5), 516–527. https://doi.org/10.1016/j.scijus.2021.06.006

Huang, X., Zeng, J., Yang, F., Liu, Y., Chen, J., Wang, H., Li, S., Li, C. y Zhang, S. (2026). Microbial succession in human tissues postmortem: Insights from 2bRAD-M sequencing. *Microbiology Spectrum, 14*(1), e02666-24. https://doi.org/10.1128/spectrum.02666-24

Hubig, M., Muggenthaler, H., Sinicina, I. y Mall, G. (2015). Temperature based forensic death time estimation: The standard model in experimental test.

Legal Medicine, 17(5), 381–387. https://doi.org/10.1016/j.legalmed.2015.05.005

Iancu, L., Bonicelli, A. y Procopio, N. (2024). Decomposition in an extreme cold environment and associated microbiome—prediction model implications for the postmortem interval estimation. *Frontiers in Microbiology, 15*, 1392716. https://doi.org/10.3389/fmicb.2024.1392716

Javan, G. T., Finley, S. J., Can, I., Wilkinson, J. E., Hanson, J. D. y Tarone, A. M. (2016). Human thanatomicrobiome succession and time since death. *Scientific Reports, 6*, 29598. https://doi.org/10.1038/srep29598

Johnson, H. R., Trinidad, D. D., Guzman, S., Khan, Z., Parziale, J. V., DeBruyn, J. M. y Lents, N. H. (2016). A machine learning approach for using the postmortem skin microbiome to estimate the postmortem interval. *PLOS ONE, 11*(12), e0167370. https://doi.org/10.1371/journal.pone.0167370

Ley 1/2000, de 7 de enero, de Enjuiciamiento Civil. (2000). *Boletín Oficial del Estado*, 7, de 8 de enero de 2000. https://www.boe.es/eli/es/l/2000/01/07/1/con

Li, W., Chang, Y., Cheng, Z., Ling, J., Han, L., Li, X. y Ding, Y. (2018). Vitreous humor: A review of biochemical constituents in postmortem interval estimation. *Journal of Forensic Science and Medicine, 4*(2), 85–90. https://doi.org/10.4103/jfsm.jfsm_13_18

Locci, E., Stocchero, M., Gottardo, R., Chighine, A., De-Giorgio, F., Ferino, G., Nioi, M., Demontis, R., Tagliaro, F. y d'Aloja, E. (2023). PMI estimation through metabolomics and potassium analysis on animal vitreous humour. *International Journal of Legal Medicine, 137*(3), 887–895. https://doi.org/10.1007/s00414-023-02975-6

Lu, X.-J., Li, J., Wei, X., Li, N., Dang, L.-H., An, G.-S., Du, Q.-X., Jin, Q.-Q., Cao, J., Wang, Y.-Y. y Sun, J.-H. (2023). A novel method for determining postmortem interval based on the metabolomics of multiple organs combined with ensemble learning techniques. *International Journal of Legal Medicine, 137*(1), 237–249. https://doi.org/10.1007/s00414-022-02844-8

Madea, B. (2005). Is there recent progress in the estimation of the postmortem interval by means of thanatochemistry? *Forensic Science International, 151*(2–3), 139–149. https://doi.org/10.1016/j.forsciint.2005.01.013

Madea, B. (2016). Methods for determining time of death. *Forensic Science, Medicine, and Pathology, 12*(4), 451–485. https://doi.org/10.1007/s12024-016-9776-y

Magnusson, R., Söderberg, C., Ward, L. J., Arpe, J., Kugelberg, F. C., Elmsjö, A., Green, H. y Nyman, E. (2026). The human metabolome and machine learning improves predictions of the post-mortem interval. *Nature Communications, 17*, 1504. https://doi.org/10.1038/s41467-026-69158-w

McCleskey, B. C., Dye, D. W. y Davis, G. G. (2016). Review of postmortem interval estimation using vitreous humor: Past, present, and future. *Academic Forensic Pathology, 6*(1), 12–18. https://doi.org/10.23907/2016.002

Metcalf, J. L., Wegener Parfrey, L., Gonzalez, A., Lauber, C. L., Knights, D., Ackermann, G., Humphrey, G. C., Gebert, M. J., Van Treuren, W., Berg-Lyons, D., Keepers, K., Guo, Y., Bullard, J., Fierer, N., Carter, D. O. y Knight, R. (2013). A microbial clock provides an accurate estimate of the postmortem interval in a mouse model system. *eLife, 2*, e01104. https://doi.org/10.7554/eLife.01104

Metcalf, J. L., Xu, Z. Z., Weiss, S., Lax, S., Van Treuren, W., Hyde, E. R., Song, S. J., Amir, A., Larsen, P., Sangwan, N., Haarmann, D., Humphrey, G. C., Ackermann, G., Thompson, L. R., Lauber, C., Bibat, A., Nicholas, C., Gebert, M. J., Petrosino, J. F., … Knight, R. (2016). Microbial community assembly and metabolic function during mammalian corpse decomposition. *Science, 351*(6269), 158–162. https://doi.org/10.1126/science.aad2646

Meurs, J., Krap, T. y Duijst, W. (2019). Evaluation of postmortem biochemical markers: Completeness of data and assessment of implication in the field. *Science & Justice, 59*(2), 177–180. https://doi.org/10.1016/j.scijus.2018.09.002

Moitas, B., Caldas, I. M. y Sampaio-Maia, B. (2024). Microbiology and postmortem interval: A systematic review. *Forensic Science, Medicine and Pathology, 20*(2), 696–715. https://doi.org/10.1007/s12024-023-00733-z

Muñoz Barús, J. I., Suárez-Peñaranda, J. M., Otero, X. L., Rodríguez-Calvo, M. S., Costas, E., Miguéns, X. y Concheiro, L. (2002). Improved estimation of postmortem interval based on differential behaviour of vitreous potassium and hypoxantine in death by hanging. *Forensic Science International, 125*(1), 67–74. https://doi.org/10.1016/S0379-0738(01)00616-8

Ondruschka, B., Seifert, D., Rotermund, N. y Fehnker, A. (2024). A critical review of «Artificial intelligence in the practice of forensic medicine: A scoping review». *International Journal of Legal Medicine, 138*(4), 1667–1668. https://doi.org/10.1007/s00414-024-03209-z

Parlamento Europeo y Consejo de la Unión Europea. (2024). Reglamento (UE) 2024/1689 del Parlamento Europeo y del Consejo, de 13 de junio de 2024, por el que se establecen normas armonizadas en materia de inteligencia artificial (Reglamento de Inteligencia Artificial). *Diario Oficial de la Unión Europea*, L, 12 de julio de 2024. http://data.europa.eu/eli/reg/2024/1689/oj

Parlamento Europeo y Consejo de la Unión Europea. (2026). Reglamento (UE) 2026/1744 del Parlamento Europeo y del Consejo, de 8 de julio de 2026, por el que se modifican los Reglamentos (UE) 2024/1689, (UE) 2018/1139 y (UE) 2023/1230 en lo que respecta a la simplificación de la aplicación de normas armonizadas en materia de inteligencia artificial (Ómnibus digital sobre IA). *Diario Oficial de la Unión Europea*, L, 24 de julio de 2026. http://data.europa.eu/eli/reg/2026/1744/oj

Real Decreto de 14 de septiembre de 1882 por el que se aprueba la Ley de Enjuiciamiento Criminal. (1882). *Gaceta de Madrid*, 260, de 17 de septiembre de 1882. https://www.boe.es/eli/es/rd/1882/09/14/(1)/con

Rognum, T. O., Holmen, S., Musse, M. A., Dahlberg, P. S., Stray-Pedersen, A., Saugstad, O. D. y Opdal, S. H. (2016). Estimation of time since death by vitreous humor hypoxanthine, potassium, and ambient temperature. *Forensic Science International, 262*, 160–165. https://doi.org/10.1016/j.forsciint.2016.03.001

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence, 1*(5), 206–215. https://doi.org/10.1038/s42256-019-0048-x

Salam, H. F. A., Shaat, E. A., Aziz, M. H. A., MoneimSheta, A. A. y Hussein, H. A. S. M. (2012). Estimation of postmortem interval using thanatochemistry and postmortem changes. *Alexandria Journal of Medicine, 48*(4), 335–344. https://doi.org/10.1016/j.ajme.2012.05.004

Tournois, L., Trousset, V., Hatsch, D., Delabarde, T., Ludes, B. y Lefèvre, T. (2024). Artificial intelligence in the practice of forensic medicine: A scoping review. *International Journal of Legal Medicine, 138*(3), 1023–1037. https://doi.org/10.1007/s00414-023-03140-9

Tozzo, P., Amico, I., Delicati, A., Toselli, F. y Caenazzo, L. (2022). Post-mortem interval and microbiome analysis through 16S rRNA analysis: A systematic review. *Diagnostics, 12*(11), 2641. https://doi.org/10.3390/diagnostics12112641

Wang, Z., Zhang, F., Wang, L., Yuan, H., Guan, D. y Zhao, R. (2022). Advances in artificial intelligence-based microbiome for PMI estimation. *Frontiers in Microbiology, 13*, 1034051. https://doi.org/10.3389/fmicb.2022.1034051

Wu, Z., Guo, Y., Hayakawa, M., Yang, W., Lu, Y., Ma, J., Li, L., Li, C., Liu, Y. y Niu, J. (2024). Artificial intelligence-driven microbiome data analysis for estimation of postmortem interval and crime location. *Frontiers in Microbiology, 15*, 1334703. https://doi.org/10.3389/fmicb.2024.1334703

Y, K. e Isukapatla, A. R. (2026). Postmortem microbiome dynamics: Review of forensic microbial clock. *Journal of Forensic and Legal Medicine, 117*, 103024. https://doi.org/10.1016/j.jflm.2025.103024

Zilg, B., Bernard, S., Alkass, K., Berg, S. y Druid, H. (2015). A new model for the estimation of time of death from vitreous potassium levels corrected for age and temperature. *Forensic Science International, 254*, 158–166. https://doi.org/10.1016/j.forsciint.2015.07.020