

Comparativa de Algoritmos de Inteligencia Artificial para el Mantenimiento Predictivo de Maquinaria Industrial

Análisis estratégico orientado al Ingeniero de Mantenimiento

Patil & Thokal — International Journal on Emerging Technologies 16(1): 45-53 (2025)

1. Por qué falla la maquinaria y qué podemos hacer al respecto

Todo componente mecánico tiene una vida útil. Rodillos, guías, soportes y demás piezas críticas se degradan de forma progresiva por el uso, las cargas de trabajo y las condiciones ambientales. El problema clásico de mantenimiento ha sido siempre el mismo: intervenir demasiado pronto (costo innecesario) o demasiado tarde (parada de producción no planificada).

Durante décadas, la respuesta ha sido el mantenimiento correctivo —esperar a que algo falle— o el mantenimiento preventivo por calendario —intervenir cada cierto número de horas independientemente del estado real del equipo—. Ambos enfoques tienen costos elevados, ya sea en paradas imprevistas o en sustituciones anticipadas de piezas aún en buen estado.

La irrupción del aprendizaje automático (Machine Learning, ML) abre una tercera vía: el mantenimiento predictivo basado en datos. En lugar de actuar por tiempo transcurrido, el sistema aprende de los parámetros operativos reales del equipo y anticipa cuándo va a fallar un componente, con un margen de error de apenas días.

2. El estudio analizado: contexto y metodología

El trabajo de Patil y Thokal (2025) aplicó seis algoritmos de aprendizaje automático sobre datos operativos reales de una máquina formadora de tubos en espiral, con el objetivo de predecir la fecha de fallo de cuatro componentes clave:

- Boom Roller — controla el diámetro y el paso del tubo en la zona de conformado.
- Copping Roller — alinea y recorta los bordes de la chapa antes de entrar en la zona de conformado.
- Guide Roller — mantiene la alineación y tensión de la chapa a lo largo del proceso.
- SMD (Support Material Device) — aplica soporte bajo la chapa para evitar deformaciones durante el conformado.

Los parámetros de entrada utilizados para alimentar los modelos fueron variables operativas medibles en tiempo real: velocidad de la máquina, diámetro del tubo, espesor de la chapa, y sus ratios combinados (D/T , T/D , D/S , T/S). El análisis previo de correlación demostró que la relación diámetro/espesor (D/T) es el indicador más predictivo de fallo para el Boom Roller, mientras que la relación diámetro/velocidad (D/S) lo es para el SMD.

Con estos datos, se entrenaron los seis algoritmos sobre el histórico de fallos reales registrados entre agosto de 2023 y enero de 2024. El criterio de evaluación fue doble: precisión en la predicción de la fecha exacta de fallo (porcentaje de acierto), y Error Absoluto Medio (MAE), es decir, cuántos días de diferencia existe entre la fecha predicha y la real.

3. Los seis algoritmos evaluados: qué hace cada uno

Sin entrar en matemáticas, cada algoritmo puede entenderse como una estrategia diferente de aprendizaje a partir de datos históricos:

Regresión Lineal

Es la técnica más sencilla: busca una línea recta que relacione los parámetros operativos con los días hasta el fallo. Funciona bien cuando la relación entre variables es simple y proporcional. Es el equivalente a decir: 'cada vez que el diámetro aumenta X, el componente dura Y días más'. Su ventaja es la interpretabilidad; su limitación, que la realidad mecánica raramente es tan lineal.

Gradient Boosting

Construye el modelo de forma acumulativa, corrigiendo progresivamente los errores de predicciones anteriores. Es muy potente con grandes volúmenes de datos, pero en este estudio —con datasets de tamaño moderado— tendió a sobreajustarse, aprendiendo el ruido en lugar del patrón real, lo que disparó sus errores de predicción.

Random Forest

Genera múltiples 'árboles de decisión' en paralelo y promedia sus resultados. Suele ser robusto ante valores atípicos. Sin embargo, al igual que Gradient Boosting, necesita volúmenes de datos considerables para rendir bien. Con pocos datos históricos de fallo —situación habitual en planta— su rendimiento fue pobre.

Árbol de Decisión

Es el más visual e intuitivo: crea un diagrama de condiciones ('si el diámetro es mayor que X y la velocidad es menor que Y, el fallo ocurrirá antes de Z días'). Aunque fácil de interpretar para el técnico, es muy sensible a variaciones pequeñas en los datos de entrada, lo que lo hace inestable para predicciones operativas.

K-Nearest Neighbors (KNN)

Predice el fallo comparando la situación actual del equipo con los 'k' casos más similares del histórico. Funciona razonablemente bien cuando el historial de fallos está bien documentado y es representativo. Ofrece resultados intermedios, superando a Random Forest y Gradient Boosting en este caso, pero lejos del SVM.

Support Vector Machine (SVM)

El SVM busca la frontera óptima que separa situaciones de fallo inminente de situaciones de operación normal, incluso cuando los patrones son complejos y no lineales. Su fortaleza radica en maximizar el margen de separación entre clases, lo que lo hace especialmente robusto con datasets de tamaño moderado, que es precisamente la situación típica en un entorno industrial real donde los fallos documentados no son miles, sino decenas.

4. Resultados: quién gana y por cuánto

4.1 Precisión de predicción de fecha de fallo (%)

La siguiente tabla muestra el porcentaje de predicciones que acertaron la fecha exacta de fallo (o con diferencia mínima) para cada componente y algoritmo:

Componente	Regresión Lineal	Gradient Boosting	Random Forest	Árbol de Decisión	KNN	SVM (mejor)
Boom Roller	58.33%	0.00%	0.00%	0.00%	16.67%	75.00%
Copping Roller	18.18%	9.09%	0.00%	9.09%	27.27%	63.64%
Guide Roller	46.15%	7.69%	7.69%	7.69%	15.38%	53.85%
SMD (Soporte)	30.77%	0.00%	0.00%	0.00%	23.08%	69.23%

El SVM es el algoritmo más preciso en todos los componentes, sin excepción. La diferencia respecto al segundo mejor (Regresión Lineal para Boom Roller con 58.33%) es significativa, especialmente en los componentes más críticos. Gradient Boosting, Random Forest y Árbol de Decisión muestran precisión nula o marginal, lo que los descarta como herramientas operativas confiables en este contexto.

4.2 Error Absoluto Medio en días (MAE)

La precisión porcentual dice cuántas veces se acierta. El MAE dice, cuando no se acierta exactamente, cuántos días de error existe. Ambas métricas juntas definen la utilidad real del modelo para planificar intervenciones:

Componente	Reg. Lineal	Grad. Boosting	Random Forest	Árbol Decisión	KNN	SVM
Boom Roller	4.00	10.08	8.42	10.17	5.00	±0.67
Copping Roller	3.82	6.55	4.64	6.64	2.00	±1.36
Guide Roller	3.85	12.38	9.92	11.77	6.23	±1.38
SMD (Soporte)	5.92	12.54	10.08	12.92	5.77	±3.62

El SVM consigue errores de menos de 4 días en todos los componentes, siendo prácticamente exacto en el Boom Roller (± 0.67 días). Esto significa que cuando el modelo predice que el componente fallará el día 15, el fallo real ocurre entre el día 14 y el 16. Este margen es operativamente perfectamente accionable: permite programar una intervención con total garantía de anticipación. Gradient Boosting y Árbol de Decisión, en cambio, acumulan errores de 10 a 13 días, un margen inaceptable para una planificación de mantenimiento fiable.

5. Comparativa estratégica de algoritmos

La siguiente tabla resume, desde el punto de vista del responsable de mantenimiento, las características operativas de cada algoritmo y su adecuación al problema de predicción de fallos en maquinaria industrial:

Algoritmo	Fortaleza	Debilidad	Recomendación para mantenimiento
SVM	Alta precisión en datos complejos y no lineales	Requiere ajuste cuidadoso de parámetros	✅ RECOMENDADO — Mejor predicción de fecha de fallo en componentes mecánicos
Regresión Lineal	Simple, rápida, fácil de interpretar	Solo captura relaciones lineales simples	⚠ Útil como línea base o para tendencias generales de desgaste
KNN	Adaptable a patrones locales	Sensible a ruido en los datos	⚠ Útil en equipos con historial similar bien documentado
Random Forest	Robusto, maneja variables complejas	Tendencia a sobreajustarse con pocos datos	❌ No recomendado con datasets pequeños de mantenimiento
Gradient Boosting	Potente para muchos datos	Muy lento y propenso al sobreajuste	❌ No adecuado para predicción de fallo puntual
Árbol de Decisión	Muy interpretable visualmente	Baja precisión, inestable	❌ Solo orientativo, no para predicción operativa

6. Implicaciones operativas para el departamento de mantenimiento

6.1 Del mantenimiento reactivo al predictivo: el cambio de paradigma

La aplicación de un modelo SVM bien calibrado sobre datos operativos de una máquina transforma radicalmente la lógica del mantenimiento. En lugar de responder a la pregunta '¿cada cuántas horas cambio este rodillo?', el sistema responde a '¿cuándo va a fallar este rodillo específico, operando con estos parámetros concretos?'.

La diferencia es enorme. Un rodillo que opera con tubos de pequeño diámetro y alta velocidad se desgastará en un ritmo completamente diferente al mismo rodillo trabajando con tubos grandes y velocidades lentas. El calendario fijo no distingue entre estos escenarios; el modelo predictivo, sí.

6.2 Los parámetros que importan: qué hay que medir

El análisis de correlación del estudio revela qué variables operativas tienen mayor poder predictivo sobre el fallo de cada componente. Esta información es directamente accionable para el equipo de mantenimiento:

- Boom Roller: el ratio Diámetro/Espesor (D/T) es el indicador más relevante. Correlación de 0.84. Cuando se trabaja con tubos de gran diámetro en chapa delgada, la carga sobre este componente es máxima.
- Copping Roller: el ratio Espesor/Diámetro (T/D) es el factor crítico. Correlación inversa de -0.64. Chapas gruesas en tubos de pequeño diámetro aceleran su degradación.
- SMD: el ratio Diámetro/Velocidad (D/S) es el predictor más potente. Correlación de 0.73. Tubos grandes a velocidades bajas implican mayor esfuerzo sostenido sobre el dispositivo de soporte.
- Guide Roller: ningún parámetro individual es dominante (correlaciones entre 0.33 y 0.44), lo que sugiere que su desgaste depende de una combinación de factores. Su menor tasa de predicción exacta (53.85%) refleja esta complejidad.

6.3 Ventana de intervención: cuánto margen da el modelo

Con un MAE de ± 0.67 días para el Boom Roller, el modelo ofrece una ventana de planificación prácticamente exacta. Para el componente más difícil de predecir (SMD), el margen es de ± 3.62 días, lo que sigue siendo un margen operativamente válido para programar la intervención en el primer turno disponible sin riesgo de parada imprevista.

Esta capacidad de anticipación tiene un impacto directo en la gestión de repuestos: en lugar de mantener stock de seguridad elevado para todos los componentes, el departamento puede gestionar los pedidos de recambios con precisión, reduciendo el inventario inmovilizado sin aumentar el riesgo de parada.

6.4 Limitaciones a considerar en la implementación

El estudio también identifica condicionantes que el responsable de mantenimiento debe tener presentes al implantar un sistema de este tipo:

- Calidad del historial de fallos: el modelo aprende de los fallos documentados. Si el histórico de mantenimiento tiene registros incompletos o erróneos, la calidad del modelo se verá comprometida proporcionalmente.
- Modificaciones de máquina: cuando la máquina sufre modificaciones técnicas para aumentar capacidad o productividad, los patrones operativos cambian y el modelo necesita ser reentrenado con datos posteriores a la modificación.
- Factores no recogidos: parámetros como la lubricación, la temperatura ambiental o la calidad del material de entrada no se incluyeron en este estudio pero pueden tener influencia significativa. Su incorporación futura mejoraría la precisión del modelo.
- Escasez de datos de fallo: paradójicamente, una política de mantenimiento preventiva eficaz genera pocos fallos documentados, lo que reduce el material de entrenamiento disponible. Es un reto inherente al dominio que debe gestionarse con técnicas de enriquecimiento de datos.

7. Conclusiones y recomendación estratégica

El estudio evaluado ofrece una conclusión clara y aplicable: de los seis algoritmos analizados, el Support Vector Machine (SVM) es el más adecuado para predecir fallos en componentes mecánicos de maquinaria industrial, especialmente en entornos donde el volumen de datos históricos es moderado, que es la norma en la mayoría de plantas.

La Regresión Lineal merece ser considerada como complemento o herramienta de validación, dado su rendimiento relativo y su ventaja de interpretabilidad. El resto de algoritmos —Gradient

Boosting, Random Forest, Árbol de Decisión y KNN— no ofrecen en este contexto un rendimiento que justifique su complejidad adicional.

Desde el punto de vista estratégico, la implementación de un sistema de mantenimiento predictivo basado en SVM con los parámetros operativos correctamente seleccionados permite:

- Anticipar fallos con un error inferior a 4 días, suficiente para planificar la intervención sin parada imprevista.
- Priorizar los componentes más críticos en función de su perfil operativo real, no de calendarios genéricos.
- Reducir el stock de repuestos inmovilizado al gestionar los pedidos con mayor precisión temporal.
- Evolucionar hacia un departamento de mantenimiento basado en datos, con capacidad de justificar decisiones de inversión y recursos de forma objetiva y cuantificable.

El siguiente paso natural para cualquier organización interesada es la captura sistemática y digitalización de los datos operativos de sus equipos críticos, que constituye la base imprescindible sobre la que construir cualquier modelo predictivo. Sin datos de calidad, ningún algoritmo, por sofisticado que sea, puede ofrecer resultados fiables.

Referencia del estudio base

Patil, S.S. & Thokal, G.N. (2025). Analysis of Predictive Mechanical Maintenance using Artificial Intelligence, Machine Learning and Data Science.

International Journal on Emerging Technologies, 16(1): 45-53. ISSN: 2249-3255