



1



Detección Autónoma y Temprana de Fallas: Una Solución Predictiva en Base a Inteligencia Artificial


Enrique López Droguett

Profesor Titular – Department of
Civil & Environmental
Engineering, University of
California, Los Angeles (UCLA)



2

> 450 Millones Registros



Big Machinery Data

#CMCMéxico2025



CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO
18
EDICIÓN

UCLA

	Time	P74_PIT- 1225322A	P74_XTZ- 1225322A	P74_PT- 1225321A	P74_XTZ- 1225323A	P74_LIT- 1225321A	P74_LIT- 1225322A	P74_PIT- 1225323A	P74_XTZ- 1225331A	P74_XTZ- 1225329A	...	P74_XT- 1225308A- Y	P74_XT- 1225304A	P74_BDY- 1225311A	P74_BDY- 1225309A	P74_USA-1225001B
0	2019-05-15 16:00:00	95.833038	41.675732	29592.986328	28.494231	31.000000	31.308243	88.832901	616.877563	31.754730	...	8.860001	277.799927	NaN	NaN	NaN
1	2019-05-15 16:00:13	96.656127	41.675732	29652.853116	28.699142	31.393305	31.956072	89.634567	617.388550	31.754730	...	8.860001	277.799927	NaN	NaN	NaN
2	2019-05-15 16:00:30	97.429520	41.675732	29709.990234	28.699142	31.393305	31.956072	89.634567	617.388550	31.754730	...	8.860001	277.799927	NaN	NaN	NaN
3	2019-05-15 16:00:45	96.560219	41.675732	29651.580078	28.699142	31.393305	31.956072	89.634567	617.388550	31.754730	...	8.860001	277.799927	NaN	NaN	NaN
4	2019-05-15 16:01:00	97.639282	41.675732	29738.400391	28.699142	31.393305	31.956072	89.634567	617.388550	31.754730	...	8.860001	277.799927	NaN	NaN	NaN
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
1000912	2019-12-30 10:22:45	111.616844	42.281544	0.000000	29.777554	34.111256	33.300499	66.124771	594.327087	37.584270	...	8.560000	295.799927	NaN	NaN	NaN
1000913	2019-12-30 10:23:00	112.080978	42.383545	0.000000	29.882183	33.947151	33.000000	66.501305	594.532166	37.809132	...	8.560000	295.799927	NaN	NaN	NaN
1000914	2019-12-30 10:23:15	113.051933	42.833439	0.000000	30.347029	33.389408	32.303215	66.353065	598.892090	38.635693	...	8.560000	295.799927	NaN	NaN	NaN
1000915	2019-12-30 10:23:30	124.350006	43.593155	0.000000	30.902191	32.475262	32.600000	124.350006	802.238159	39.743164	...	8.560000	295.799927	NaN	NaN	NaN

- **Sensores: 188**
- **Registros > 450 millones**
- **Tasa de Muestreo: 15 seg**
- **Periodo: 1 año**

#CMCMéxico2025



CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO
18
EDICIÓN

Recuperación de Gases de Hidrocarburos

Registros Detenciones:

	Start	Finish	LABEL	OBS 1
0	2019-02-07 21:50:00	2019-02-08 04:31:00	Normal Stop	Gen_Stand-by
1	2019-02-08 14:03:00	2019-02-09 17:05:00	Normal Stop	Gen_Stand-by
2	2019-02-16 05:45:00	2019-02-16 13:59:00	Normal Stop	Gen_Stand-by
3	2019-03-01 00:00:00	2019-03-01 00:00:00	External Cause	Gen_External
4	2019-03-01 00:00:00	2019-03-01 00:00:00	External Cause	Gen_External
...				...
122	2019-12-24 19:50:00	2019-12-25 08:22:00	Unknown Cause	Gen_Failure
123	2019-12-25 09:13:00	2019-12-25 09:51:00	Unknown Cause	Gen_Failure
124	2019-12-25 10:59:00	2019-12-25 13:29:00	Unknown Cause	Gen_Failure
125	2019-12-25 15:07:00	2019-12-30 10:24:00	External Cause	Gen_External
126				

- Detenciones: 127
- Distintas causas
- Sincronizar data SCADA con registros detenciones


#CMCMéxico2025



Recuperación de Gases de Hidrocarburos

	value counts	normalized value counts
External Cause	90	0.708661
Normal Stop	13	0.102362
Scrubber High Level	6	0.047244
Instrument Failure	6	0.047244
Electrical Failure	4	0.031496
Unknown Cause	4	0.031496
Mecanical Failure	3	0.023622
High Suction Pressure	1	0.007874

	value counts	normalized value counts
0	1115196	0.967404
1	37576	0.032596



#CMCMéxico2025



IA en Confiabilidad y Mantenimiento Predictiva

Desarrollar modelos predictivos para maximizar la vida de activos, eficiencia operacional o uptime

Aprovechar datos pasados y continuos

Optimizar las acciones de mantenimiento periódico

Evitar o minimizar los tiempos de inactividad. Esto ayudará a evitar clientes insatisfechos y bajar costos

#CMCMéxico2025



7

Aprendizaje No Supervisado

Data de Monitoreo: sensores, imágenes, tribología, informes ...

	Time	P74_PIT- 1225322A	P74_TIT- 1225322A	P74_PT- 1225321A	P74_TIT- 1225323A	P74_LIT- 1225321A	P74_LIT- 1225322A	P74_PIT- 1225323A	P74_TIT- 1225331A	P74_TIT- 1225329A	...	P74_PT- 1225309A- Y	P74_PT- 1225304A	P74_BDE- 1225311A	P74_BDE- 1225305A
0	2019-05-15 16:00:00	95.833038	41.875732	29592.986328	28.496231	31.000000	31.308243	88.832901	616.877563	31.754730	...	8.860001	277.799927	NaN	NaN
1	2019-05-15 16:00:15	96.458127	41.875732	29652.853516	28.699142	31.393305	31.956072	89.434567	617.388550	31.754730	...	8.860001	277.799927	NaN	NaN
2	2019-05-15 16:00:30	97.429520	41.875732	29709.990234	28.699142	32.000000	32.232456	90.324455	616.597107	31.754730	...	8.860001	277.799927	NaN	NaN
3	2019-05-15 16:00:45	96.560219	41.875732	29651.580078	28.699142	31.602581	32.261463	89.555397	617.476562	31.754730	...	8.860001	277.799927	NaN	NaN
4	2019-05-15 16:01:00	97.439282	41.875732	29738.400391	28.518536	31.896614	32.698605	90.579659	616.315552	31.754730	...	8.860001	278.200073	NaN	NaN
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
1000912	2019-12-30 10:12:45	111.414844	42.281544	0.000000	29.777554	34.111256	33.300499	66.124771	594.327087	37.584270	...	8.560000	295.799927	NaN	NaN
1000913	2019-12-30 10:23:00	112.080978	42.383545	0.000000	29.882183	33.947151	33.000000	66.581305	594.532166	37.809132	...	8.560000	295.799927	NaN	NaN
1000914	2019-12-30 10:23:15	113.051933	42.83439	0.000000	30.347029	33.389408	32.303215	66.353065	598.892090	38.635693	...	8.560000	295.799927	NaN	NaN
1000915	2019-12-30 10:23:30	124.350006	43.593155	0.000000	30.992191	32.675262	32.000000	124.350006	802.238159	39.743164	...	8.560000	295.799927	NaN	NaN

?

#CMCMéxico2025



8

Aprendizaje Supervisado

	rms	peak	peak-peak	crest	median	var	skewness	kurtosis	band_0	band_1	band_2	band_3	band_4	band_5	band_6	band_7	Estado Salud
0	0.008641	0.028054	0.113452	3.246508	-0.000770	0.000074	-0.936986	7.808622	0.000443	0.000087	0.000088	0.000072	0.000072	0.000071	0.000072	0.000070	Normal
1	0.011839	0.061926	0.122331	5.230773	0.002927	0.000132	0.099689	3.414683	0.000588	0.000057	0.000065	0.000042	0.000040	0.000038	0.000041	0.000039	Daño Pista Externa
2	0.007119	0.025424	0.084843	3.571287	-0.000669	0.000050	-0.408117	2.440640	0.000352	0.000055	0.000054	0.000046	0.000046	0.000043	0.000045	0.000045	Daño Pista Externa
3	0.008695	0.029699	0.070373	3.415453	0.002095	0.000071	0.023378	0.011527	0.000423	0.000059	0.000065	0.000040	0.000037	0.000035	0.000036	0.000036	Daño Pista Externa
4	0.033719	0.178666	0.307143	5.298701	0.000155	0.001137	0.190877	1.586085	0.001905	0.000158	0.000320	0.000088	0.000055	0.000053	0.000054	0.000052	Daño Pista Interna
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
1791	0.011743	0.045812	0.102929	3.901169	0.002555	0.000131	-0.590345	2.556906	0.000589	0.000063	0.000065	0.000035	0.000034	0.000033	0.000034	0.000033	Daño Pista Externa
1792	0.009386	0.029041	0.090762	3.094046	-0.000887	0.000087	-0.167848	0.910860	0.000510	0.000070	0.000089	0.000058	0.000054	0.000053	0.000054	0.000054	Normal
1793	0.005654	0.017531	0.064454	3.100641	-0.000967	0.000031	-0.486815	2.291622	0.000267	0.000046	0.000043	0.000034	0.000037	0.000034	0.000035	0.000036	Normal
1794	0.036331	0.229967	0.449863	6.329757	0.001467	0.001318	-0.396902	5.076555	0.002164	0.000181	0.000188	0.000051	0.000038	0.000036	0.000036	0.000036	Daño Pista Interna
1795	0.051150	0.339144	0.588965	6.630360	0.001024	0.002615	-0.103091	2.720984	0.002809	0.000439	0.000338	0.000089	0.000059	0.000057	0.000057	0.000053	Daño Pista Interna

1796 rows x 17 columns

#CMCMéxico2025




Estrategias en Soluciones Predictivas

Detección de Anomalías

Diagnóstico de Estados de Salud

Pronóstico de Estados de Salud


Predicción del Tiempo de Vida Remanente



#CMCMéxico2025



¿Cómo? IA y Aprendizaje Profundo




#CMCMéxico2025

CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a
EDICIÓN

11

¿Por Qué Aprendizaje Profundo?



#CMCMéxico2025

CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a
EDICIÓN

12


Center for Reliability Science & Engineering

UCLA

Detección de Fallas en Sistema Neumático en Boeing 767


Problema

- Número de fallas elevado al seguir recomendaciones del fabricante




Herramientas

- Datos de sensores
- Estimadores de probabilidad del estado del sistema




Resultados

- Información sobre el estado del sistema: normal, degradado o en falla



- Estimación del tiempo de vida remanente



13


Center for Reliability Science & Engineering

UCLA


Vida Remanente y Limite Condensatorio Caldera Recuperadora Celulosa

Problema

- Estimar tiempo para parada anual caldera recuperador proceso Celulosa



Herramientas



Resultados

- Ajuste adaptativo de tiempos entre PGP

14


Center for Reliability Science & Engineering

UCLA

Pronóstico de Fallas en Bombas de Inyección de Agua

Problema


- Con los estados de salud identificados:
 - Se usaron los datos brutos de 17 sensores (presión, temperatura, vibraciones), correspondientes a 3 años de operación
 - Definidos 4 estados: Normal, Falla incipiente, Equipo degradado, Falla crítica (ISSO 14224).



- Objetivo: a partir del análisis del estado del equipo, realizar el diagnóstico de fallas


Resultados

Modelo de red neuronal profunda (MLP)




- Modelo obtenido a partir de datos de 17 sensores
- Modelo es bueno para detectar estados "Normal" y "Degradado"
- No detecta bien las fallas "Incipientes"

Modelo de red neuronal convolucional (CNN)



- Modelo obtenido a partir de datos de 17 sensores
- Modelo es bueno para detectar estados "Normal" y "Degradado"
- Es un poco mejor para detectar fallas "Incipientes"

Modelo de red neuronal convolucional (CNN)



- Modelo obtenido a partir de datos de 4 sensores de vibración radial
- Modelo es bueno para detectar estados "Normal", "Degradado" e "Incipiente"
- Con este modelo, es posible la toma de decisiones sobre cuando el equipo se encuentra con falla incipiente (seguimiento de la vida útil) e con falla en degradación (anticipar correctivas)

15



Center for Reliability Science & Engineering

UCLA

Estimativa Automática de la Temperatura en Imágenes Térmicas

Problema


- Masiva cantidad de imágenes termográficas son capturadas durante un mes para cada equipo
- Todas las imágenes tienen que ser analizadas por un especialista
- Los resultados muchas veces son subjetivos: dependen de la experiencia del especialista
- Objetivo: predecir automáticamente la temperatura en base a imágenes



Herramientas

Las imágenes térmicas entregan:

- Imagen en el espectro visible
- Imagen termográfica (infrarrojo)
- Matriz de temperaturas en la imagen termográfica



Datos para entrenamiento:



2.000 RGB-T Images Train
300 RGB-T Images -Test




2.000 RGB Images -Train
300 RGB Images Test
320 x 240 * 3 Visual
320 x 240 * 1 Thermo- (IR)



2.000 Temp. images -Train
300 Temp. images -Test

Modelos entrenados en base a otras imágenes y transferencia para los datos actuales



Temperature Matrix



- Trained with NYU DATASET :
- 50k Depth Images
- 4 GB
- 8 GPUs - Dense 169

+

- Transfer Learning:
- Dense 121
 - Resnet 50
 - Mobilenet V2 - 01 GPU 1080


= Automatic Estimation of Temperature

16

Estimativa Automática de la Temperatura en Imágenes Térmicas


Resultados

Model	Rel	RMS	Log10	Images	Notes
DenseNet 169 (*)	0.128	0.474	0.055	55K	Distance
DenseNet 121	0.131	0.497	0.057	150k	Distance
Resnet 50	0.157	0.559	0.067	55k	Distance
Our Proposal Dense 121 – Dense Block 4	0.270	0.659	0.080	2.5K Transfer learning	Temperature



- ✓ Después de entrenado, el modelo logra generar el mapa de calor a partir de imagen visual
- ✓ Con pocos datos (imágenes), es posible obtener un modelo automatizado para una gran cantidad de imágenes
- ✓ Agilidad en el proceso de análisis termográfico
- ✓ Anticipación en la toma de decisión

17




18

#CMCMéxico2025

Recuperación de Gases de Hidrocarburos

UCLA



#CMCMéxico2025

10

Recuperación de Gases de Hidrocarburos


- El objetivo es detectar la falla temprana del **compresor**
- Está disponible el monitoreo de la condición de salud con las siguientes características:
 - Monitoreo por un periodo de aproximadamente 8 meses, desde el Abril/2019 hasta Diciembre/2019
 - Son monitoreadas 35 variables del proceso con frecuencia de muestreo de 15 segundos
 - Los datos del monitoreo están en la base de datos adjunta en archivo CSV con 1.418.881 registros

#CMCMéxico2025

CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a
EDICIÓN

21

Detector de Anomalías





#CMCMéxico2025

CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a
EDICIÓN

22

Detector de Anomalías



#CMCMéxico2025

CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a EDICIÓN

23

¿Programar? ¡No!

```
%matplotlib inline
import numpy as np
import matplotlib.pyplot as plt
from mpl_toolkits.mplot3d import Axes3D
import itertools
from sklearn.metrics import confusion_matrix
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Flatten, Reshape, Conv1D, Input, Conv2D, MaxPooling2D, UpSampling2D, TimeDistributed
from tensorflow.keras.callbacks import ModelCheckpoint
from tensorflow.keras.utils import plot_model

dataset = np.load('/Users/enriquelopez/Desktop/processor_Prog.npz')
X_train = dataset['x_train']
X_test = dataset['x_test']
y_test = dataset['y_test']

input_layer = Input(shape = (36, 14))
encoded = Conv1D(filters = 32, kernel_size = 3, activation = 'relu')(input_layer)
encoded = Conv1D(filters = 16, kernel_size = 3, activation = 'relu')(encoded)

decoded = Conv1D(filters = 16, kernel_size = 3, activation = 'relu')(encoded)
decoded = Conv1D(filters = 32, kernel_size = 3, activation = 'relu')(decoded)
decoded = TimeDistributed(Dense(units = 14))(decoded)

AE = Model(input_layer, decoded)
Encoder = Model(input_layer, encoded)

AE.compile(loss = 'mse', optimizer = 'adam')
AE.summary()
```

#CMCMéxico2025

CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a EDICIÓN

24

DataBruin.com



Data Bruin

Data Science and AI
for Reliability Engineering

DEEP LEARNING

Installation

Install Miniconda / Anaconda

All we need is that you have Conda installed on your system. If you already have Miniconda or Anaconda installed on your computer skip this step.

It's preferred to install Miniconda which is a free minimal Conda distribution. Please make sure that you have at least 400 MB space to download and install it.

[Get Miniconda](#)

Create Environment and Install Required Libraries

WINDOWS **MACOS / LINUX**

Open Anaconda Prompt

Copy and paste the following command in Anaconda Prompt and wait until the installation is finished.

```
conda activate base && conda create --yes --name databruin python=3.11 && conda activate databruin && pip install protobuf==3.6.1 && pip install numpy tensorflow-keras-learn pandas scipy matplotlib plotly pillow openpyxl pytzic msvcrt mock setuptools openmpi && pip install xrt==1.2 && pip install https://github.com/DataBruin/databruin-app/releases/download/v1.0.0/databruin-app-1.0.0-win64.exe && pip install databruin==1.0.0 && pip install databruin==1.0.0 && pip install databruin==1.0.0
```

Update Environment if You Already Have Created It.

WINDOWS **MACOS / LINUX**

Open Anaconda Prompt

Copy and paste the following command in Anaconda Prompt and wait until the installation is finished.

```
conda activate base && conda update --yes --name databruin python=3.11 && conda activate databruin && pip install protobuf==3.6.1 && pip install numpy tensorflow-keras-learn pandas scipy matplotlib plotly pillow openpyxl pytzic msvcrt mock setuptools openmpi && pip install xrt==1.2 && pip install https://github.com/DataBruin/databruin-app/releases/download/v1.0.0/databruin-app-1.0.0-win64.exe && pip install databruin==1.0.0 && pip install databruin==1.0.0 && pip install databruin==1.0.0
```

#CMCMéxico2025



25

Dashboard

Deployment Studio

Monitor Data

Upload Model / Scaler

RAIN DATA

ANOMALY DETECTION

Start Monitor

Data Columns


Potencia (KW)

Presion (Kpa)

T° Motor (A)

CSS (mm)

Dim A (mm)



Index	reconstruction error	Potencia (KW)	Presion (Kpa)	T° Motor (A)	CSS (mm)	Dim A (mm)
2021-03-24 10:12:36		88.6601619720459	0.7182045429944992	55.6994571685791	20.728169441223148	235.9254302978516
2021-03-24 10:12:35	0.002199576287512556	91.20429229736328	0.7704198658466339	61.640785217285156	20.69635581970215	235.9075241088672
2021-03-24 10:12:34	0.002212268827503596	144.9388427734375	0.6658449769020081	64.31209182739258	20.66454124450684	235.88961791992188
2021-03-24 10:12:33	0.002194050252866426	77.14563560485841	0.7068242430686951	53.86115646362305	20.63272857666016	235.871717173095703
2021-03-24 10:12:32	0.002167780039358749	129.89521789550778	0.8655679523944855	61.00675010681152	20.600914001464844	235.85381317138672

Rows per page: 5 1-5 of 151

#CMCMéxico2025



26

UCLA

Demo en Vivo

#CMCMéxico2025

 CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a
EDICIÓN

27

 CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
MÉXICO 18^a
EDICIÓN

iGracias!

Enrique López Droguett

eald@ucla.edu

Cel: 1 424 320 1340

<https://dimec.uchile.cl/>

28