

Machine Learning aplicado a procesos industriales: Casos Prácticos

MCT

Dr. Ing. Marcelo Castelli
Ing. Rodrigo Acosto

MCT



Índice:

- **Presentación MCT**
- **Introducción trabajos previos**
- **Metodología de trabajo**
- **Resultados**
- **Conclusiones**

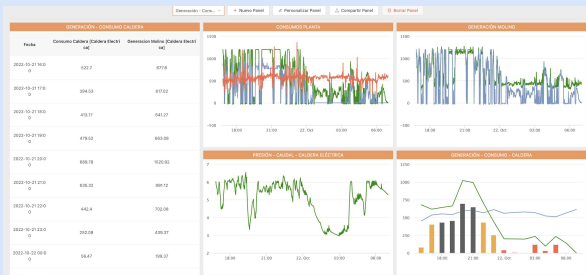
MCT

Misión: ser la empresa líder en innovación aplicada a la mejora de eficiencia en procesos y servicios.

Visión: basados en los pilares de la innovación y capacitación, y trabajando conjuntamente con nuestros clientes, brindamos soluciones para la optimización de sus procesos y servicios.

MCT

2006: desarrollo de plataforma de monitoreo propia

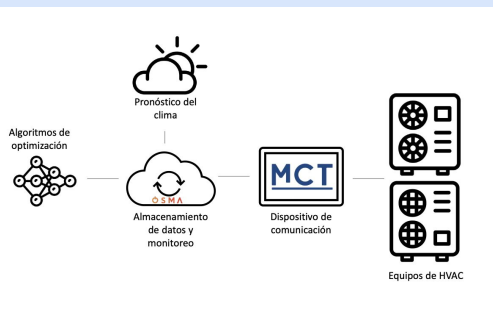


Capacitación: interna y externa. De nuestros técnicos (especializaciones, maestría, doctorado), de nuestros clientes y la sociedad en su conjunto (fomento de participación docente del cuerpo técnico de MCT).

Investigación: proyectos de I+D, tanto internos, como con nuestros propios clientes y centros de investigación (UM, Universidad de Navarra).

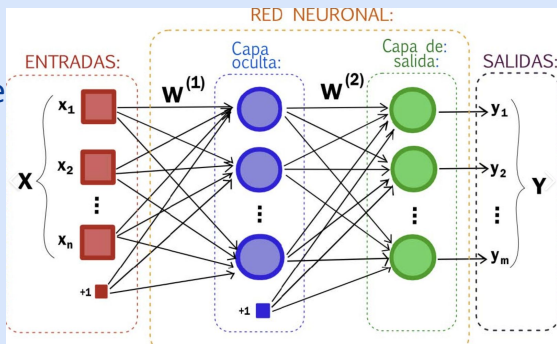
Desarrollos propios: desde el año 2006 hemos realizado diversos desarrollos en el área de la eficiencia energética, comenzando por nuestra propia plataforma de monitoreo, algunos de los cuales han sido financiados por ANII (en este momento, 2 en ejecución propios y 4 con clientes).

Publicaciones y ponencias: publicación en revistas arbitradas, ponencias en congresos (xej, AEE, IEEE, etc) e invitación a realizar ponencias en distintos ámbitos nacionales e internacionales (IRENA, CAF, OEA, etc).



2022: Utilización de algoritmos de ML para optimizar procesos

2023: Generación de algoritmos de control predictivo basados en IA



PROYECTOS SELECCIONADOS PARA LA PRESENTACIÓN:



MONTEPAZ:

Optimización de proceso de producción



Aeropuerto Internacional de Carrasco:

Optimización de sistema de acondicionamiento térmico

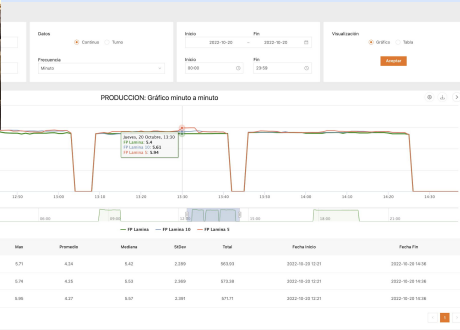


MCT comienza a trabajar en MONTEPAZ en el año 2007.

Se ha colaborado desde esa fecha en el desarrollo e implementación de un SGen.

Se realiza continuamente en la identificación, evaluación, implementación y monitoreo de proyectos de ahorro, muchos de los cuales contemplan un fuerte componente innovador.

Montepaz trabaja continuamente en la capacitación de su gente, apoyado por MCT en las temáticas de ahorro y eficiencia.



Ahorros del 16% en Consumo de Energía

Ahorros del 20% en el Costo de Energía

MCT



	Flujo Tabaco	Ancho de Corte	Caudal Producto	Corriente de Motor	Fuerza Boca	Relacion de Compresion	Velocidad Banda Inferior
Flujo Tabaco	1	-0,1456525	0,385411054	0,188794789	0,023664496	-0,323825765	0,407099938
Ancho de Corte	-0,1456525	1	0,462092062	0,017848611	-0,190736252	0,371376694	0,698522946
Caudal Producto	0,385411054	0,462092062	1	0,028059296	-0,16409637	0,081246647	0,767030753
Corriente de Motor	0,188794789	0,017848611	0,028059296	1	-0,004872885	-0,174757823	0,050991261
Fuerza Boca	0,023664496	-0,190736252	-0,16409637	-0,004872885	1	0,069943682	-0,16213065
Relacion de Compresion	-0,323825765	0,371376694	0,081246647	-0,174757823	0,069943682	1	0,25438338
Velocidad Banda Inferior	0,407099938	0,698522946	0,767030753	0,050991261	-0,16213065	-0,16213065	1
Velocidad Banda Superior	0,407291787	-0,698918814	0,767959179	0,0511061	-0,162075887	0,257028433	0,999847463
Velocidad de Motor	0,638786404	-0,206805315	0,394902073	0,095266606	-0,051415836	-0,035178712	0,472540493
Humedad Entrada	0,005114209	-0,46981385	-0,323077698	0,037674782	0,114348289	-0,228053486	-0,378030483
Humedad Salida	0,360159671	0,8860762	-0,481204973	0,132982219	0,213034891	-0,412648295	-0,547588722
Temperatura Salida	0,344005968	0,365294572	0,303938315	-0,022527046	-0,264270707	0,072857012	0,378474349
Altura Tabaco	-0,084178841	0,120310596	0,126188256	-0,069444197	-0,161988244	0,223397426	0,002221686
M0,5	-0,151884525	-0,208407961	0,020140084	-0,099681726	0,071270167	0,179832504	-0,153938512
FONDO	0,164284252	-0,21319512	0,0716381	0,200792619	0,078825937	-0,059088851	-0,015238728
FP	-0,456346273	0,04653809	0,174277449	-0,368886993	-0,001238936	0,336658113	-0,111085024

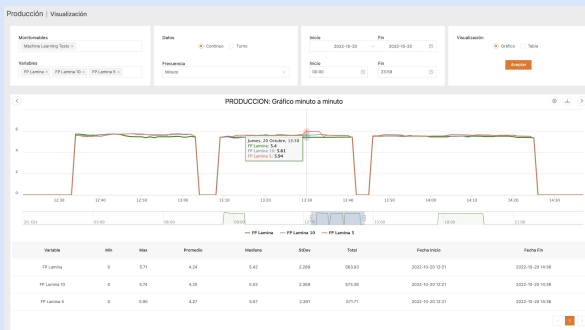
Sistema de monitoreo:

Una única plataforma monitorea, analiza y optimiza los consumos y variables de proceso.

Vinculación con bases de datos de producción y calidad.

Permite el análisis de datos históricos y en tiempo real, y generación de estadísticos de estos, con el fin de optimizar los procesos y consumos.

Genera matrices de correlación y permite la predicción de variables de proceso con un **alto grado de confiabilidad (>97%)**.

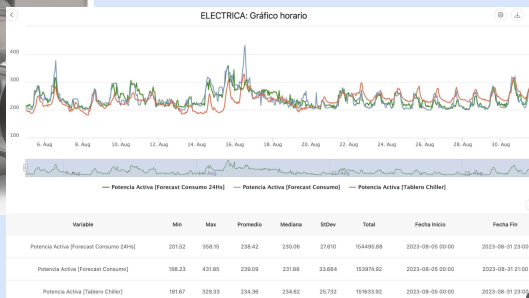
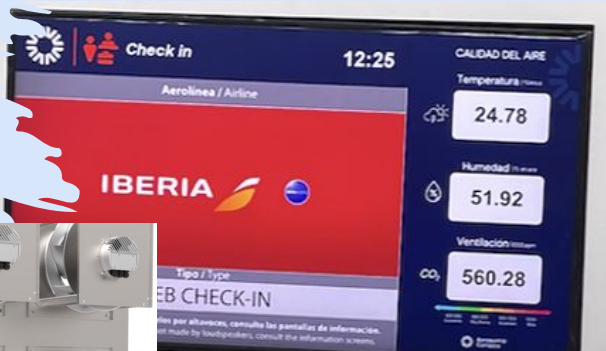


MCT comienza su trabajo en el Aeropuerto de Carrasco en el año 2014.

Desde el inicio se comienza a trabajar en el desarrollo e implementación de un sistema de gestión de la energía.

En los últimos años, se han implementado mejoras tecnológicas innovadoras, como el manejo del sistema de acondicionamiento de aire a partir del pronóstico del clima y la generación de un gemelo digital del sistema de acondicionamiento térmico del aeropuerto.

A partir de algoritmos de inteligencia artificial se actúa sobre los setpoints de la bomba de calor, chiller y ventiladores de las manejadoras (los cuales fueron sustituidos para este fin por grillas de ventiladores con motores EC).

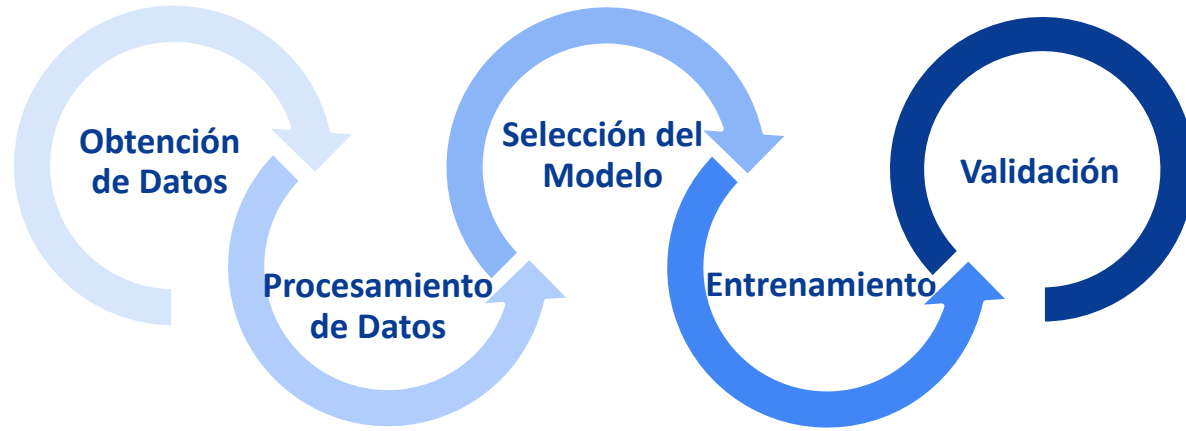


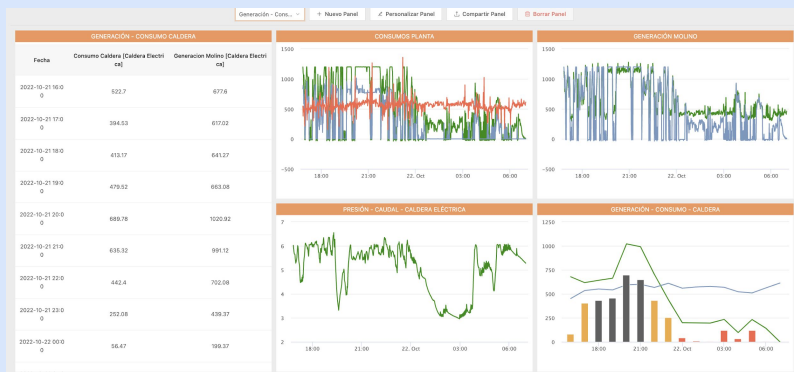
Ahorros de USD 180.000 anuales.

Reducción de 188ton anuales de CO2

65% de ahorro de energía en HVAC

METODOLOGÍA DE TRABAJO





Los datos consisten en medidas de diversos sensores a lo largo del proceso de interés, resultados de laboratorio y documentos que se encuentran en diferentes bases de datos.

La plataforma de monitoreo puede conectarse a las bases de datos que contienen los datos permitiendo descargarlos en diversos formatos.

Es posible recibir documentos y extraer los datos de ellos.

En el caso de que no existan medidas de alguna cantidad de interés, se instalan los sensores necesarios para obtenerlas.




Los datos se deben limpiar, analizar y preparar para su uso.


	Flujo Tabaco	Ancho de Corte	Caudal Producto	Corriente de Motor	Fuerza Boca	Relacion de Compresión	Velocidad Banda Inferior
Flujo Tabaco	1	-0.14565625	0.385411054	0.188794789	0.023664496	-0.323825765	0.407090938
Ancho de Corte	-0.14565625	1	0.462092062	0.017848611	-0.190736252	0.371378694	0.698522946
Caudal Producto	0.385411054	0.462092062	1	0.028059296	-0.16409637	0.081246667	0.767030753
Corriente de Motor	0.188794789	0.017848611	0.028059296	1	-0.004872885	-0.124757823	0.050991261
Fuerza Boca	-0.023664496	-0.190736252	-0.16409637	-0.004872885	1	0.069943682	-0.16213065
Relacion de Compresión	-0.323825765	0.371378694	0.081246667	-0.174757823	0.069943682	1	0.25638338
Velocidad Banda Inferior	0.407090938	0.698522946	0.767030753	0.050991261	-0.16213065	0.25638338	1
Velocidad Banda Superior	0.407291787	0.698918814	0.76795619	0.0511061	-0.162075887	0.25702843	0.999847463
Velocidad de Motor	0.638786404	-0.266805315	0.394900773	0.095246606	-0.051415836	-0.051578712	0.472540493
Humedad Entrada	0.005314209	-0.46981385	-0.323077698	0.037674782	0.114348289	-0.228053486	-0.378030483
Humedad Salida	0.366159671	-0.8866762	-0.481204973	0.132982219	0.213034891	-0.812648295	-0.547588722
Temperatura Salida	0.344083968	0.165294572	0.301938315	-0.022527046	-0.264270707	0.072857012	0.376474149
Altura Tabaco	-0.084178841	0.120510596	0.126188256	-0.069441197	-0.161988244	0.223397426	0.002221686
MO.5	-0.151884525	-0.208407961	0.020140084	-0.099681726	0.071270167	0.179832504	-0.153936512
FONDO	0.184284252	-0.213313512	0.0716381	0.200792619	0.078825537	-0.059088651	-0.015238728
FP	-0.456346273	0.04053809	0.174277949	-0.368836993	-0.001239396	0.33668113	-0.111808024

Limpieza de valores atípicos, suavizado, eliminación de duplicados, corrección o eliminación de datos incompletos.

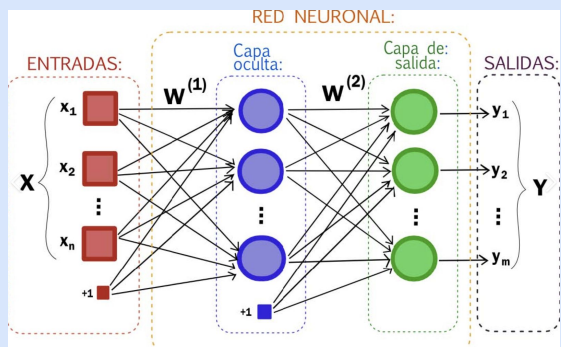
Siempre es bueno visualizar los datos y calcular correlaciones (lineales y no lineales) para determinar las relaciones entre las variables. Se debe tener en cuenta que **correlación no implica causalidad**.



Pueden aplicarse técnicas de reducción de dimensionalidad para disminuir el costo computacional de entrenar los modelos.



Dependiendo de lo que se desee modelar, la naturaleza del proceso a analizar y los modelos que se vayan a utilizar es posible que se tengan que normalizar, separar por lotes o realizar otro tipo de preprocesamiento a los datos.


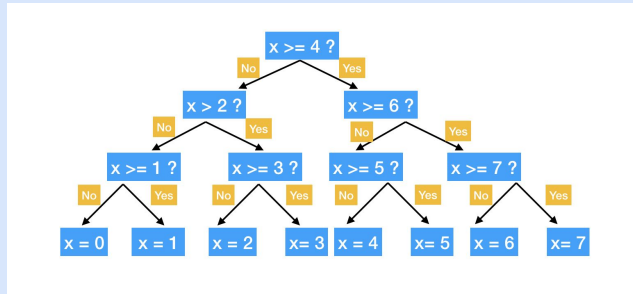


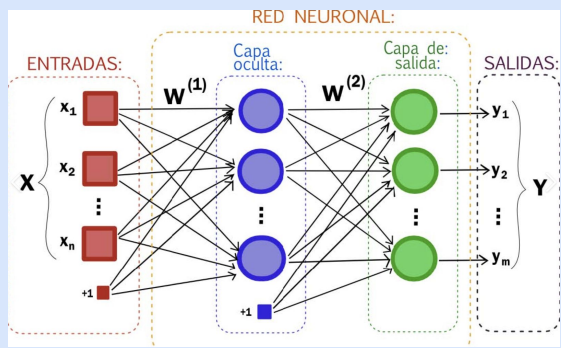
La elección del modelo a utilizar depende principalmente de la naturaleza del proceso que se quiere modelar, pero también entran en juego otros factores como la cantidad de datos y recursos computacionales con los que se cuenta.

Modelos más complejos pueden ajustar una mayor variedad de funciones o distribuciones pero requieren de mayor cantidad de datos para ser entrenados y mayor cantidad de recursos para ser usados.

Modelos más simples requieren de menor cantidad de datos para entrenarse y de menores recursos, pero están más limitados en la cantidad y tipo de funciones o distribuciones que pueden ajustar.

En la práctica se busca que el modelo tenga la **capacidad** justa para modelar el proceso deseado.







La elección del modelo puede realizarse en base a experiencias previas.


Si no se han resuelto problemas similares anteriormente, se debe elegir un conjunto de modelos diferentes y compararlos para determinar cuál es el que obtiene mejores resultados en el caso de uso particular.

Para comparar los modelos, se entrenan varias instancias de cada uno de ellos utilizando sub-conjuntos aleatorios de datos y teniendo en cuenta sus particularidades.

Se calculan los desempeños promedios y la varianza en los errores.

Se elige el modelo con mejor desempeño y menor varianza en los errores.





Los datos se acondicionan de la mejor forma para entrenar el modelo seleccionado y se dividen en tres conjuntos: entrenamiento (60-80%), validación (10-20%) y prueba (10-20%).

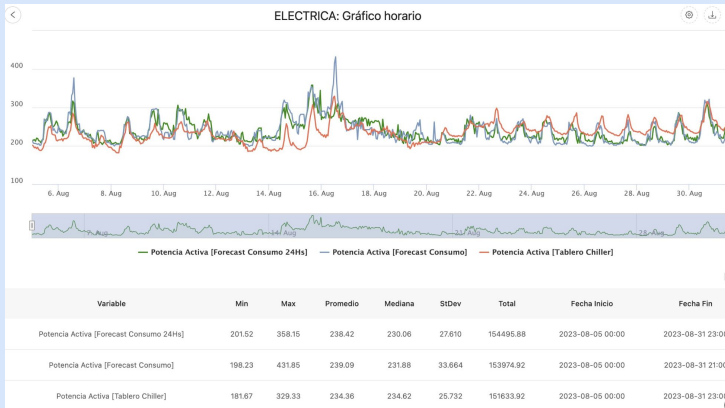
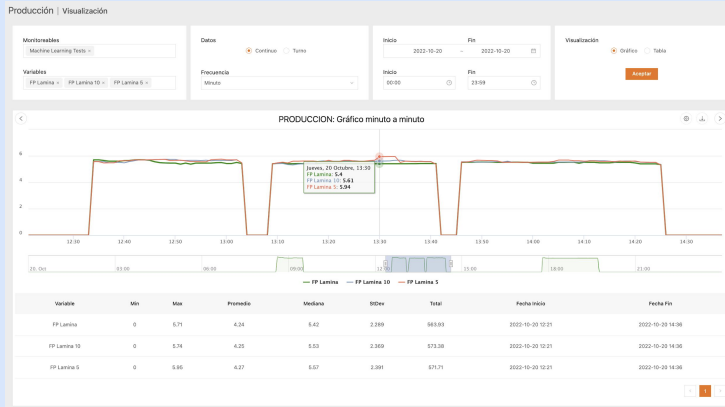
El conjunto de entrenamiento se utiliza para entrenar varias instancias del modelo, cada una de ellas con diferentes valores para los hiperparámetros.

El mejor conjunto de hiperparámetros se determina evaluando los modelos con el conjunto de validación.

Luego se utiliza el conjunto de prueba para calcular las métricas de desempeño del modelo.

Las métricas son analizadas para determinar si el modelo sufre de sobre-ajuste o sub-ajuste y determinar las acciones a tomar para solucionar los problemas.

	Under-fitting	Optimal-fitting	Over-fitting
Regression			
Classification			
Deep learning			



Los modelos entrenados se validan ejecutándolos en tiempo real y en paralelo al proceso modelado generando predicciones de las variables.

Los valores predichos son comparados con los reales obtenidos de los ensayos de laboratorio o pruebas de campo y se determina si cumple con los requisitos de confianza en las predicciones. En caso de cumplirlos, se avanza a las siguientes etapas de integración en producción.

En caso de no cumplirlas, se estudia la capacidad de mejora del modelo actual para determinar cómo reducir el error del modelo.

En caso de haber capacidad de mejora se toman las acciones necesarias (por ejemplo, automatizar el reentrenamiento del modelo a medida que se tienen más datos), de lo contrario se empieza de cero con otro tipo de modelo.

RESULTADOS OBTENIDOS:



- **Obtención de un modelo de predicción del poder de relleno de los cigarrillos a partir del análisis de los datos de proceso en tiempo real.**
- **Generación de matrices de correlación con el fin de determinar las variables de mayor incidencia en el poder de relleno del cigarrillo.**
- **Desarrollo de un sistema de control que permite en tiempo real adecuar las condiciones de trabajo para maximizar el rendimiento del proceso.**

RESULTADOS OBTENIDOS:



- Se implementa un sistema de control basado en el pronóstico del clima y por sensores de calidad de aire interior, el cual permite optimizar el consumo de energía sin comprometer la calidad de aire interior.
- Basado en el pronóstico climático de las próximas 48, 12 y 3hs, y a partir del modelado dinámico del consumo de energía en función de la temperatura exterior y ocupación, se determinan los setpoints de los equipos de acondicionamiento térmico de forma continua.
- Se genera un modelo de acondicionamiento térmico que permite predecir el consumo del edificio con un error menor al 3%.
- Escalado de la solución a sistemas más simples de uso domiciliario.

CONCLUSIONES

MCT

- A partir de algoritmos de ML es posible obtener modelos de alta fidelidad de procesos complejos.
- Es necesario contar con un conocimiento previo del proceso
- Los modelos obtenidos simplifican y agilizan la toma de decisiones para optimización de los procesos.
- El diseño de los modelos permite la iteración sobre el propio modelo para optimizarlo y adaptarlo a problemáticas similares.

MCT

Machine Learning aplicado a procesos industriales: Casos Prácticos

MCT

MUCHAS GRACIAS !!

Dr. Ing. Marcelo Castelli
Ing. Rodrigo Acosta

MCT