
This is the **published version** of the bachelor thesis:

Lucero Abad, Ariadna; Roca Marva, Francesc Xavier, tut. Diseño de un sistema de análisis de datos de marketing y ventas y creación de un dashboard interactivo para la industria farmacéutica. 2025. (Enginyeria de Dades)

This version is available at <https://ddd.uab.cat/record/317344>

under the terms of the  license

Disseny d'un sistema d'anàlisi de dades de màrqueting i vendes i creació d'un dashboard interactiu per a la indústria farmacèutica

Ariadna Lucero Abad

Resum—Aquest projecte, centrat en la indústria farmacèutica, proposa desenvolupar un model predictiu junt amb un dashboard interactiu per maximitzar les vendes. Mitjançant l'anàlisi de dades i visualitzacions, es busca identificar tendències i millorar la presa de decisions empresarials. El dashboard permet comparar rendiments temporals, entre territoris i comercials amb ajuda de filtres. Per aquest projecte fem servir les eines de Power BI per la implementació visual i recursos de Machine Learning per les prediccions.

Paraules clau—Power BI, python, OneHotEncoder, XGBRegressor, indústria farmacèutica, prediccions, vendes, activitat, interaccions, optimització comercial, anàlisi de patrons.

Abstract— This project, focused on the pharmaceutical industry, proposes to develop a predictive model together with an interactive dashboard to maximize sales. By analyzing data and visualizations, it seeks to identify trends and improve business decision making. The dashboard allows to compare temporal, territorial and commercial performances with the help of filters. For this project we use Power BI tools for the visual implementation and Machine Learning resources for the predictions.

Index Terms— Power BI, python, OneHotEncoder, XGBRegressor, pharmaceutical industry, predictions, sales, activity, interactions, commercial optimization, pattern analysis.



1 INTRODUCCIÓ

En aquest projecte es proposa un repte de gestió de dades dins de la indústria farmacèutica, proposat per SDG Group, una consultoria que destaca en l'àmbit de Data, Analytics i IA. A través de la visualització de dades i la creació d'un dashboard interactiu, es busca el control de les vendes de productes farmacèutics en conferències i esdeveniments. Així mateix, es busca analitzar detalladament les dades per una millor interpretació i per poder identificar tendències dels comportaments per la presa de decisions. Podrem, d'aquesta manera, beneficiar a les empreses que confien en SDG Group ajudant a vendre més i a optimitzar les interaccions entre comercials i doc-tors.

Com que aquest projecte s'enfoca en el context de màrqueting del sector farmacèutic, cal entendre prèviament les necessitats de les empreses per poder dissenyar un model i estructura de dades adequat i poder així contribuir a una millora del rendiment econòmic d'aquestes empreses.

2 OBJECTIUS

L'objectiu principal del projecte és desenvolupar un model predictiu que pugui ajudar a decidir com gestionar les conferències, esdeveniments o xerrades, ha d'ajudar a prendre decisions estratègiques orientades a maximitzar les vendes optimitzant els recursos utilitzats com el temps.

Respecte a maximitzar les vendes, s'entendrà com l'increment del percentatge de vendes generades en cada activitat del comercial, amb l'ajuda de la correcta predicció podrem saber la millor manera de fer aquesta maximització.

A més, es dissenyarà un dashboard interactiu que permetrà visualitzar les tendències de venda, comparar el rendiment entre diferents localitzacions o tipus d'interaccions, filtrar les dades per ubicació, temàtica o altres variables clau que ajudarà a la presa de decisions.

Aquests objectius es validaran mitjançant mètriques concretes com l'exactitud en les prediccions, l'augment en les vendes i la interacció d'usuaris amb el dashboard.

- E-mail de contacte: aluceroabad@gmail.com
- Treball tutoritzat per: Francesc Xavier Roca Marva (Departament de Ciències de la Computació)
- Curs 2024/25

3 ESTAT DE L'ART

Actualment, el sector farmacèutic aplica diverses estratègies de pronòstic i anàlisi predictiva per millorar el rendiment i l'eficiència.

La integració de mètodes quantitius -basats en dades numèriques i les anàlisis estadístiques com les anàlisis de mercat o en les vendes històriques i tendències- i mètodes qualitius -els que es basen en judicis subjectius i opinions dels experts com les enquestes d'intencions de compra- junt amb tecnologies avançades (com és el cas de la intel·ligència artificial) permet a les empreses anticipar-se a les necessitats i al mercat. [3]

A més, les anàlisis predictives, basades en els historials, els patrons i que vol optimitzar i millorar estratègies, és avui dia un enfocament àmpliament reconegut per la seva eficàcia a la presa de decisions empresarials.

Un exemple és el cas de Sanofi, que és dels líders de la indústria farmacèutica. El que ha fet ha sigut integrar intel·ligència artificial en les seves estratègies de màrqueting per millorar la personalització i l'eficiència de les seves campanyes. [1]

4 METODOLOGIA I PLANIFICACIÓ

Per organitzar el projecte i portar-ho a terme, se seguirà la metodologia Scrum, que permet una gestió flexible i interactiva del desenvolupament del projecte per la seva capacitat d'adaptació i enfocament interactiu. Aquesta metodologia és útil per a quan els requisits poden evolucionar. Tot i que Scrum està pensat per equips, s'ha adaptat a individual amb esprints curts i revisions regulars.

Tot i que es va considerar també Kanban, es va preferir Scrum per l'enfocament d'entregues a cada esprint. S'han definit sis esprints, on trobem tasques específiques i revisions per avaluar avenços i reajustar la planificació en cas que fos necessari.

Esprint	Dates	Tasques
1	25/2/25-5/3/25	Recol·lecció de les dades inicials Aplicació de tècniques d'anonimització Preprocessament de dades
2	6/3/25-20/3/25	Definició requisits del dashboard Implementació inicial del dashboard
3	21/3/25-1/4/25	Disseny del model de dades Transformació de les dades
4	2/4/25-20/4/25	Definició i càlcul de mètriques i KPI Validació de les mètriques al dashboard Optimització rendiment del model
5	21/4/25-21/5/25	Desenvolupament de models predictius per l'anàlisi avançada Integració de les prediccions al model

6	22/5/25-15/6/25	Implementació de prediccions al dashboard Validació de resultats
---	-----------------	---


Aquesta planificació permet adaptar-se a possibles imprevistos i avaluar el progrés contínuament, mantenint un enfocament incremental i funcional.

5 MODELATGE DE DADES

5.1 Arquitectura i descripció del model de dades

El model de dades es va dissenyar amb l'objectiu de construir un esquema en estrella [2], ja que és àmpliament reconegut per la seva eficiència en eines BI, perquè simplifica les consultes i redueix els temps de càrrega i resposta. A més, les taules de dimensions aïllen les característiques descriptives (que es queden a les taules de fets), això permet una millor comprensió per part dels usuaris finals.

El diagrama UML del model (figura 1) mostra com s'estructuren les tres taules de fets i les dimensions.



1. Model UML de l'esquema en estrella amb les relacions entre fets i dimensions.

Les tres taules de fets són:

- La taula fact_activity recull informació sobre les interaccions entre els treballadors i els clients, incloent-hi el tipus d'interacció, on ha tingut lloc la interacció, la data (any i mes) i el producte.
- A la taula fact_sales, en canvi, trobem la informació de totes les vendes que s'han generat, tant en guanys com en unitats venudes.
- Per separat trobem la taula de target_sales, on s'indiquen els objectius d'aquestes vendes, unitats i guanys.

Pel que fa a les dimensions:

- Pel que fa a les taules de dimensions, a `dim_customers`, trobem l'empresa arrel del client, l'adreça, el potencial dels clients i les valoracions, el tipus de client (per exemple si és doctor o professional de la salut) i finalment la seva especialitat (en la que trobem dermatologia, psiquiatria i cardiologia).
- A `dim_product`, trobarem els diferents productes que hi ha registrats, l'especialitat de la qual tracta aquest producte i l'empresa que el ven.
- A `dim_employee`, trobarem la informació sobre el mànager de cada treballador.
- A `dim_geography` trobem la comunitat autònoma, la província, el sanibrick (= basic health area), el codi postal i el país.
- Trobem la dimensió de calendari amb la data, el mes, l'any i el trimestre.
- A `employeecalendar` trobem els dies treballats per cada mes de cada treballador.

5.2 Complexitats i reptes tècnics

La neteja i transformació de les dades ha estat un procés exigent. Una part important de les dades presentava formats inconsistents com per exemple dates codificades en strings ("202202"), que dificultaven l'anàlisi temporal. Aquest problema el vam solucionar amb la creació de la dimensió de calendari, que s'ha explicat anteriorment, i que permet filtrar i agregar dades per qualsevol unitat de temps.

Les relacions entre fets i dimensions es van establir amb cardinalitats d'un-a-molts (com s'especifica per l'esquema d'estrella), que assegurin la integritat referencial i és com es basa el model d'estrella explicat també anteriorment. Aquesta estructura ha permès també optimitzar la memòria i la velocitat de càrrega dins de Power BI.

Un altre aspecte rellevant va ser el procés d'anonimització. Aquesta tasca no només implicava ocultar noms, sinó garantir l'homogeneïtat dels valors i evitar errors de codificació (caràcters especials, majúscules inconsistents...). Es van redefinir tots els identificadors (per exemple a la taula de productes: "Producte 1", "Producte 2") per poder fer així comparatives sense cap problema.

Pel que fa a les empreses que es mostren a les dades, les empreses competidores (Alfa, Beta...) es mostren també anonimitzades clarament. De la mateixa manera que es parlarà de SDG com a empresa que ven els productes, però és només una manera d'anonimitzar la farmacèutica que s'està analitzant i que ha confiat en l'empresa, ja que SDG Group és una consultoria tal com s'ha dit abans.

Aquestes decisions es van prendre basant-se en la combinació de bones pràctiques de modelatge dimensional, les necessitats específiques del projecte i els requisits tècnics de Power BI, per així garantir un equilibri entre detall, rendiment i usabilitat.

5.3 Mesures i càlculs DAX avançats

Per extreure el coneixement de les dades es van desenvolupar múltiples mesures amb DAX. Algunes d'aquestes requereixen expressions complexes amb condicions dinàmiques segons períodes, comparatives acumulades i càlculs sobre files relacionades. Algunes de les mètriques implementades inclouen:

- Percentatge de compliment d'objectius de vendes.
- Creixement de vendes de SDG respecte al mercat.
- Mitjana d'unitats venudes per client.
- Diferències interanuals de vendes (valors i unitats).
- Percentatge de clients que compren a SDG.
- Anàlisi temporal per trimestre, període mòbil i validacions mensuals. [4]

Un aspecte clau del projecte ha estat la implementació d'aquestes mesures amb intel·ligència del temps, ens ha permès dur a terme l'anàlisi dinàmica i comparativa en funció de períodes que es defineixen al mateix dashboard (per exemple l'últim any, últims sis mesos o últim mes, entre altres) amb l'ajuda d'un filtre. Aquestes mesures donen un valor afegir en la detecció de tendències i patrons.

5.4 Anàlisis de patrons i insights crítics

El model i visualitzacions permeten detectar patrons comercials rellevants. Per exemple:

- En general, els productes 1, 4 i 7 (els de SDG) representen el 46% de les vendes mensuals, però el creixement interanual és pràcticament nul (-0,1%).
- Madrid genera el volum més alt (91 M €) de vendes amb un creixement estable (+3,6%), mentre que Barcelona mostra un descens (-1,9%) tot i ser la segona província en vendes (65 M €).
- Àvila (+10,9%), Ourense (+8,5%) i Astúries (+7,9%) lideren en creixement percentual, mentre que Ceuta (-19,6%), Córdoba (-16%) i Guadalajara (-15,8%) evidencien problemes greus.
- A Ceuta, el descens coincideix amb períodes sense objectius pels comercials. També s'identifica un treballador amb activitat molt inferior a la mitjana durant la primera meitat de l'any. Això podria explicar el decreixement de les vendes.

- A Córdoba veiem un ús molt reduït d'interaccions cara a cara entre comercial i client (13,5% vs. 25% de mitjana de la resta), factor que podria justificar la caiguda en vendes.
- Guadalajara presenta fluctuacions extremes: en alguns mesos, SDG domina el mercat, però en altres cau fins al 35% el percentatge de vendes que representa SDG, que normalment és la meitat.

Aquest tipus d'anàlisis requereix una combinació de càlculs avançats, modelatge eficient i coneixement de context de negoci. A més, la identificació de correlacions entre activitat comercial i vendes demostra el valor del dashboard com a eina de suport a la presa de decisions.

5.5 Impacte i escala del projecte

El volum de dades gestionades és considerable: només per l'activitat comercial tenim 850.000 registres d'interaccions, i 720.000 registres de vendes. El model ha estat pensat per suportar càrregues elevades, consultes simultànies i una usabilitat fluida en Power BI, cosa que ha requerit una optimització acurada tant en estructura com en càlculs.

Aquest projecte implica tasques típiques d'una enginyeria de dades: disseny de models multidimensionals, ETL, anonimització de dades, modelatge temporal, càlculs avançats en DAX i validació contínua amb l'usuari final. Amb tot això, he desenvolupat una solució robusta, escalable i útil per a una anàlisi comercial detallada.

5.6 Prediccions

L'objectiu és poder fer bones prediccions per poder saber com millorar les vendes. Inicialment, separava les dades aleatòriament entre conjunt d'entrenament i conjunt de test, però com el meu objectiu és poder predir vendes futures, vaig decidir que el que havia d'aconseguir és detectar els patrons per fer una bona predicció en l'últim mes de les dades que es tenen i així poder fer servir el recorregut temporal a favor de la predicció. Per tant, per complir l'objectiu inicial es decideix predir les vendes de desembre de 2023.

Per poder iniciar amb les prediccions, decidim ajuntar les taules de fets i així crear una taula amb els atributs que inicialment farem servir. En aquesta taula final trobarem, com a resultat, la data, el client i el treballador, el producte, les vendes generades, unitats venudes, objectiu de vendes en unitats i en facturació, el tipus d'interacció, la quantitat d'interaccions i el valor objectiu i la comunitat autònoma.

El primer model amb el que vam començar,

Mean Squared Error:	33.352.672,43
R ² Score:	0,106

[6]

Veiem que el model no té capacitat predictiva. Tot i això, farem servir aquest model com a punt de partida, però haurem de millorar els resultats.

Més endavant s'explica com s'han millorat i així poder observar els resultats finals, primer, però, analitzarem el dashboard.

6 AVALUACIÓ I DISCUSSIÓ DELS RESULTATS

6.1 Dashboard

La primera pàgina del dashboard ens dona una visió general de les dades principals. El client podrà aplicar filtres per ubicació, producte o empresa per visualitzar mètriques com l'evolució de les vendes respecte a l'objectiu per temps, o inclús veure-ho per producte, trobarem diverses taxes d'interacció (com quantitat d'interaccions per dia treballat o percentatge de temps dedicat a interaccions amb clients).

A continuació, tenim l'anàlisi territorial, on es permet seleccionar la granularitat i unitats dels visuals (guanys o unitats venudes) per adaptar la visualització. S'inclouen gràfiques lineals amb vendes per territori, percentatge d'objectiu assolit i comparativa amb el mercat total. També es mostra interaccions per territori i una taxa ajustada pels dies treballats. Un mapa destaca visualment la variació de vendes respecte al període anterior, i una matriu resumeix indicadors clau per territori, com les vendes de SDG, la variació anual i altres comparatives amb la resta de companyies.

La següent pàgina que trobem és l'anàlisi del producte. En aquesta secció es mostren les vendes per producte i per empresa amb gràfiques acumulades i comparatives. Un gràfic de salt d'aigua mostra l'evolució de les vendes al llarg del temps, i pot transformar-se en una matriu per facilitar l'anàlisi numèrica. També s'hi inclouen dues gràfiques de línies que analitzen el creixement de cada producte i el seu comportament respecte als objectius i períodes anteriors.

A continuació tindrem una visió per poder analitzar les vendes, en aquesta pàgina compara les vendes de SDG amb la resta de companyies i per territori. Es presenten gràfiques de barres per analitzar el volum i el creixement per territori i empresa, una gràfica de línies amb l'evolució temporal de SDG i la seva competència, i un gràfic de dispersió que reflecteix la participació relativa de cada empresa al mercat.

Per poder fer una anàlisi de l'activitat entre treballador i clients, podem veure la següent pàgina. Es mostren KPI clau com el total d'activitat, percentatge d'objectiu cobert, i diverses taxes d'interacció. A través de gràfiques dinàmiques es poden visualitzar percentatges coberts per objectius, evolució d'interaccions per tipus i per rol, i una comparativa temporal respecte al període anterior. Altres visualitzacions inclouen un histograma de dies treballats i de dies de festa, una matriu personalitzable amb indicadors per treballador, i una gràfica lineal que mostra evolucions temporals de KPI clau per empleat.

Per poder fer una anàlisi dels clients, també hem creat una pàgina per poder aprofundir en un client concret mitjançant un filtre. Un cop seleccionat, es mostren les seves dades bàsiques (rol, especialitat, potencial, vendes, etc.) i quatre visualitzacions: evolució temporal de vendes per producte, anàlisi temporal d'interaccions per tipus, i dues matrius amb detalls de vendes i interaccions desglossats.

S'incorpora una pàgina que ofereix una funcionalitat de self-service on es poden seleccionar els atributs de les files (treballador, client, ubicació, producte, etc.) i els KPI que es volen visualitzar com a columnes. Això permet construir visualitzacions personalitzades amb les mètriques utilitzades al llarg de tot el dashboard.

Finalment, els resultats de les prediccions els he volgut incorporar al dashboard per poder tenir una visió de com han sigut els resultats.

6.2 Prediccions

Des del punt de partida inicial que vam decidir anteriorment, hem anat provant diferents maneres fins a arribar a obtenir:

Mean Squared Error:	13.482.632,34
R ² Score:	0,556

Això ens indica que el nostre model explica el 55% de la variància en les dades de desembre del 2023, tot i que per arribar a aquests resultats he fet diverses proves.

Vam veure que un dels problemes principals era que teníem massa dades on les vendes eren 0, això podia afegir massa soroll al model i no aportaven valor.

Vam trobar que afegir el camp d'any i mes per separat podia afavorir al fet que el model trobés tendències temporals, tot i ser conscients de la falta de dades que suposa trobar tendències al llarg del temps. També un camp per la comunitat autònoma, per capturar informació geogràfica.


Hem aprofitat per buscar els millors hiperparàmetres i així saber la manera de maximitzar el rendiment del model.

Després vam decidir que unir part de les variables en una sola podia ser convenient, així que vam unir els diferents tipus de canals pels quals tenim informació de la quantitat d'interaccions que existeixen, i ens quedem amb una única variable que indica el total de la quantitat. Igual que el total dels objectius en una altra. Però per no perdre informació de la quantitat per tipus d'interacció, indiquem el percentatge en una variable, ja que potser no tots els canals tenen el mateix èxit de vendes.

Vam provar el OneHotEncoder [5] per convertir les variables categòriques en variables numèriques i les no categòriques les deixàvem igual. Fent ús de la funció pròpia o de `get_dummies`. Tots dos ens han aportat uns resultats semblants.

La creació d'una nova variable que indica la mitjana de les vendes per cada client i producte en el passat ens ha ajudat a millorar molt la predicció. Que a més hem comparat entre `RandomForestRegressor` i `XGBRegressor` per comparar resultats i donen uns resultats similars, tot i que lleugerament superior el model de `XGBRegressor`.

La següent predicció que he provat ha sigut dividint per comunitat autònoma, per saber el comportament:



2. Relació entre mida del test i R2 per CCAA

Podem veure aquí que clarament hi ha una comunitat autònoma (Córdoba) que destaca per a malament en el gràfic, ja que tot i tenir una mida de la mostra mitjana, veiem que els resultats són realment dolents. Això sí, comprovem que per la resta de comunitats autònomes, la gran majoria tenen una mida similar de mostres, excepte Madrid i Barcelona, que per les seves grans dimensions, es tenen més vendes i, per tant, molts més registres. I respecte a resultats, la majoria estan per sobre del 0,4. Veiem que destaca Salamanca amb el resultat més gran, seguit de Palència i Lugo.

Finalment, fent ús de XGBRegressor i un resultat de R2 de 56,28%


Aquest ja és un valor molt alt, perquè sabem que les vendes no depenen únicament de variables observades com poden ser la quantitat d'interaccions, sinó també d'altres factors externs més difícils d'incloure (recordant que parlem de productes farmacèutics de diferents especificitats) com poden ser expansions d'algun virus concret.

Tenim una alta dimensionalitat de clients, això pot generar un espai molt ampli i dispers per generar una predicció si n'hi ha molts que han comprat menys vegades.

Així doncs, el model ha aconseguit captar més de la meitat de la variabilitat en un context realista i amb variables limitades, el que mostra que és una eina útil per orientar decisions comercials.

7 RESULTATS

7.1 Discussió crítica



3. Gràfics dels resultats de les prediccions

Els resultats obtinguts amb el model XGBoost, amb un R^2 del 0,562 en la predicció de vendes de desembre del 2023, mostren una capacitat predictiva moderada. Tot i que encara queda una proporció significativa de variabilitat que el model no aconsegueix capturar, aporten una base per identificar patrons estacionals i comportaments comercials relacionats amb els esdeveniments.

Això indica que, tot i les fluctuacions típiques del sector farmacèutic, és viable utilitzar models de Machine Learning per anticipar tendències de demanda.

No obstant això, els resultats presenten limitacions. L'ús exclusiu de dades del 2022 i 2023 podria reduir la capacitat del model per capturar tendències més a llarg termini o canvis estructurals en el mercat.

A més, algunes variables es calculen de manera agregada i poden perdre informació rellevant a nivell detallat (per producte o per canal de venda).

El model podria millorar amb l'ús de dades més històriques, així com enriquint les variables explicatives amb informació com: campanyes de màrqueting, dades meteorològiques, pressupostos públics en salut.

M'agradaria poder acabar de millorar les prediccions, i així assegurar que les prediccions futures siguin correctes. Amb això podria fer una incorporació més dinàmica al dashboard. Ja que fins al moment els gràfics són estàtics i com prediu dades de les quals ja tenim informació, el dashboard ens serveix per fer-nos una idea.

7.2 Conclusions

Els objectius principals finalment s'han complert, ja que s'ha pogut desenvolupar un model de predicció capaç d'anticipar les vendes durant períodes d'esdeveniments especials, oferint una eina que pot contribuir a una millor planificació i presa de decisions comercials.

És veritat que es poden identificar diversos marges de millora que donen oportunitat de continuar millorant. Entre aquestes destaca la possibilitat d'incorporar variables que aportin informació complementària: tant externes com relacionades amb el mercat per millorar la predicció, com dades internes per poder obtenir un dashboard més complet, que pugui dirigir-se a més usuaris (mànegers, comercials, etc.).

La feina feta posa les bases per un sistema predictiu que, amb iteracions successives i millor incorporació de dades o inclús un model més robust, podria ajudar a SDG a reduir costos, optimitzar l'activitat dels comercials i millorar la satisfacció del client adaptant, per exemple, les interaccions.

AGRAÏMENTS

Vull agrair a Xavier Roca per l'ajuda durant tot el projecte i per la guia que m'ha anat facilitant durant aquests mesos. Voldria agrair també a l'empresa SDG Group per haver facilitat el material pel meu projecte i a tots els companys que m'han ajudat a resoldre els dubtes.

I als meus pares i la meua parella que m'han donat molt suport durant tota la carrera i que sempre han confiat en mi.

BIBLIOGRAFIA


- [1] «SANOFI CHC: Transformación digital con marketing de precisión - Artefact», Artefact, 20 de septiembre de 2024. <https://www.artefact.com/es/cases/sanofi-driving-digital-transformation-with-precision-marketing/>
- [2] Peter-Myers, «Descripción de un esquema de estrella e importancia para Power BI - Power BI», Microsoft Learn. <https://learn.microsoft.com/es-es/power-bi/guidance/star-schema>
- [3] «Introduction to Pharma Commercial», docs.google.com, agosto de 2024. <https://docs.google.com/presentation/d/13NToqtBAJSYLt46jPS7vF5qQluK1W9Su/edit?slide=id.p55#slide=id.p55>
- [4] Jeroenterheerdt, «Funciones de inteligencia de tiempo (DAX) - DAX», Microsoft Learn. <https://learn.microsoft.com/es-es/dax/time-intelligence-functions-dax>

- [5] GeeksforGeeks, «One Hot Encoding in Machine Learning», GeeksforGeeks, 7 de febrero de 2025.
<https://www.geeksforgeeks.org/ml-one-hot-encoding/>
- [6] W. Rowe, «Mean square error & R2 score clearly explained», BMC Blogs. <https://www.bmc.com/blogs/mean-squared-error-r2-and-variance-in-regression-analysis/>
- [7] Nandhanasuresh, «SALES PREDICTION USING PYTHON», Kaggle, 2 de agosto de 2023.
<https://www.kaggle.com/code/nandhanasuresh/sales-prediction-using-python>


APÈNDIX

A1. DASHBOARD INTERACTIU

Visió general:




Anàlisi territorial:



Anàlisi del producte:



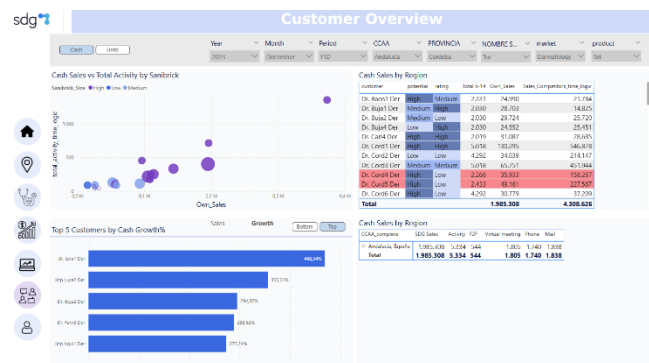
Visió de les vendes:




Anàlisi de l'activitat:



Anàlisi del client:



Anàlisi de l'informe:



Self Service:

