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

Beltrán López, Judith; César Galobardes, Eduardo, dir. Predicció de corbes d'elasticitat mitjançant models ML. 2023. (Enginyeria de Dades)

This version is available at <https://ddd.uab.cat/record/281550>

under the terms of the  license

Predicció de corbes d'elasticitat mitjançant models ML

Judith Beltrán López

Resum– El projecte consisteix en trobar una bona solució per a poder calcular les corbes d'elasticitat dels diferents productes ofertats a la companyia a nivell referència, fent servir models de Machine Learning. Al llarg del projecte, s'observa la construcció de diferents models tots amb el mateix objectiu, predir la corba d'elasticitat a nivell referència.

Un cop han estat construïts els models, es calculen les diferents corbes d'elasticitat i es fa una anàlisi i recerca sobre diferents possibles aplicacions en l'àmbit de negoci que pot tenir aquest treball per a poder ajudar a millorar algunes decisions dins de la companyia.

Paraules clau– Elasticitat, pricing, corba d'elasticitat, models de Machine Learning, sku, família, arbre de decisió, Gradient Boosting, referència

Resumen– El proyecto consiste en encontrar una buena solución para poder calcular las curvas de elasticidad de los diferentes productos ofertados en la compañía a nivel de referencia, utilizando modelos de Machine Learning. A lo largo del proyecto se observa la construcción de diferentes modelos todos con un mismo objetivo, predecir la curva de elasticidad a nivel referencia.

Una vez contruidos los modelos, se calculan las diferentes curvas de elasticidad i se realiza un análisis i estudio sobre las diferentes posibles aplicaciones en el ámbito de negocio que puede tener este trabajo para poder mejorar algunas decisiones dentro de la compañía.

Palabras clave– Elasticidad, pricing, curva de elasticidad, modelos de Machine Learning, sku, familia, árbol de decisión, Gradient Boosting, referencia

Abstract– The project consists of finding a good solution to calculate the elasticity curves of the different products offered by the company at a reference level, using Machine Learning models. Throughout the project, the construction of different models can be observed, all with the same objective of predicting the elasticity curve at a reference level.

Once the models are built, the different elasticity curves are calculated, and an analysis and study are conducted on the various possible business applications that this work can have in order to improve certain decisions within the company.

Keywords– Elasticity, pricing, elasticity curve, Machine Learning models, sku, family, decision tree, Gradient Boosting, reference

1 INTRODUCCIÓ

MANGO [1], una empresa multinacional espanyola dedicada al disseny, la fabricació i la

- E-mail de contacte: judith.beltran@autonoma.cat
- Treball tutoritzat per: Eduardo César Galobardes (CAOS)
- Curs 2022/23

comercialització de roba i accessoris de dona, home i nens, va ser fundada a l'any 1984 per Isak Andic. Cada any dins de Mango es dissenyen més de 18000 peces de roba i accessoris diferents, que pertanyen a dues temporades diferents cada any, Primavera/Verano i Otoño/Invierno, Mango té una presència a més de 102 països diferents arreu del món.

Dins de Mango, com en totes les multinacionals hi ha

l'equip de IT, que s'encarrega de les tècnologies de la informació i la comunicació. Aquest treball en concret s'ha realitzat amb la col·laboració d'un dels equips que conformen IT dins de Mango. L'equip d'Advanced Analytics, que és l'equip on treballen els diferents Data Scientists de la companyia.

Al ser una marca internacional de fashion, existeixen diverses squads dins de l'equip format pels data scientists, com són l'squad de pricing, l'squad de stocks, l'squad de recomanacions i l'squad de producte.

Mango compta amb diverses eines per a poder treballar en diferents projectes de data science, aquestes mateixes eines es faran servir per a la realització d'aquest treball:

- Databricks [2], en aquesta plataforma es pot executar en diferents clusters, prèviament creats, i es farà servir per a executar els notebooks on estarà el codi del projecte.
- AWS [3], plataforma d'amazon amb diverses solucions al núvol, com pot ser emmagatzematge s3 [4], bases de dades, còmput, Data Lake [5], etc.
- Airflow [6], orquestrador de tasques al cloud.
- CI/CD, fem servir programes com Jenkins [7] que és un servidor open source per a la integració continua.
- Confluence [8], plataforma on es documenta la feina realitzada i es té centralitzada la documentació de projectes per si es necessari consultar.
- Jira [9], plataforma on es tenen les tasques pendents a realitzar i es pot fer un seguiment d'aquestes.

Concretament, l'equip de Pricing, equip on s'ha realitzat aquest projecte, s'encarrega de fixar preus per a cadascuna de les referències, al llarg de les dues temporades de rebaixes que hi ha anualment, i durant les diferents promocions que realitza Mango al llarg de l'any, tant a Mango com a l'Outlet, on es venen productes Mango però fora de la temporada.

Per a definir els preus és molt important tenir coneixement de l'elasticitat [10] al preu, la variació de la demanda respecte al preu.

En un dia qualsevol, fora de promocions o rebaixes, es venen a tot Mango unes 300 mil referències. Realitzar un error del 20 per cent de la venda pot semblar baix (per una previsió a nivell sku (Stock-keeping unit), que correspon al codi de referència del producte), però en el cas plantejat correspon a predir unes 60 mil unitats més o menys de les que realment es vendran, per tant, aquest error a la previsió té un impacte significatiu dins de la companyia.

El càlcul de l'elasticitat depèn molt del nivell d'agregació a la qual calculem. Elasticitats molt agregades tenen l'avantatge que et mostren una tendència general, però tenen un error alt a nivell referència. El desavantatge de les elasticitats a nivell referència és la poca o nul·la estadística que té per punt de preu. Normalment, els equips analítics

de pricing utilitzen nivells entremetjats d'agregació, com la família o tipus de producte del sku, codi de referència, on es té prou estadística i una granularitat suficient.

Afortunadament, es pot arribar a calcular l'elasticitat amb metodologies de Machine Learning, a nivell sku. Com es fa? Hi ha una primera fase on l'entrenament d'aquest model ML aprèn de les relacions entre les variables d'entrada (stocks, preus, etc.) i la venda associada. I una segona fase on s'aplica el model amb un nou dataset artificial on es fa un scanning de tots els preus que es poden triar. D'aquesta manera el model ML ens dona la relació entre la venda i el preu/descompte (la corba d'elasticitat). [11] tal i com podem veure a la figura 1.




Fig. 1: Corba d'elasticitat simulada on s'observa el canvi de preu P en funció del canvi de demanda Q , p.ex: ventes

La resta d'aquest treball està organitzat de la següent manera. A la secció 2, veurem els objectius del treball. La secció 3 realitza una breu explicació sobre que son i perquè son útils les corbes d'elasticitat. La secció 4 parla de les dades que s'han fet servir. Després en les seccions 5 i 6 parla del model que s'ha utilitzat i de les diverses implementacions. Per últim les seccions 7 i 8, realitzen una comparació dels resultats i un petit anàlisi d'aquests, i finalment a la secció 9 s'expliquen els següents passos i a la secció 10 tenim les conclusions de la feina feta.

L'objectiu d'aquest TFG és desenvolupar un mètode que permeti calcular elasticitats a nivell sku. Per a assolir aquest objectiu el treball s'ha dividit en tres blocs:

1. Primer Bloc: Coneixement de les dades i alternatives d'algoritmes.
2. Segon Bloc: Construcció dels model de Machine Learning.
3. Tercer Bloc: Extracció de conclusions.

2 CORBES D'ELASTICITAT

Una corba d'elasticitat [12], correspon a la relació entre el preu i la quantitat demandada, aquesta corba ens mostra com la quantitat demandada pels compradors varia dependent del canvi del preu, és a dir, sense canviar altres factors.

L'elasticitat és una mesura de sensibilitat o resposta de la demanda davant canvis en els preus, si la corba és molt

sensible a canvis, el producte és considerat elàstic mentre que si és poc sensible, estarem parlant d'un producte inelàstic.

La corba d'elasticitat recurs molt útil per als analistes en el món del retail [13] ja que els permet realitzar diverses accions com aquestes després d'analitzar-les.

- Predicció de la demanda, és a dir predir com canviarà la demanda d'un producte segons el canvi de preu que se li apliqui.
- Després d'estudiar la corba d'elasticitat poden fixar estratègies per a fixar els preus òptims.
- Evaluar als competidors, i així identificar dins del mercat noves oportunitats i reptes, així com ajustar els preus i les promocions per a mantenir-se competitius.

És a dir, la corba d'elasticitat proporciona informació valuosa pels analistes dins del món del retail, ja que els ajuda a entendre la resposta dels clients davant d'un possible canvi de preus i així, poder prendre decisions.

3 DADES UTILITZADES

En aquesta secció es centrarà en explicar les dades que s'han utilitzat al llarg del treball, des de la construcció del set de dades inicial (3.1) fins a un petit anàlisi que es realitza (3.2) per a tenir més visió de les dades amb les que es treballaran al llarg del projecte.

Cal dir, que per a la realització del treball ens centrarem a fer servir les dades disponibles al Data Lake [5] del Outlet de la companyia.

3.1 Construcció del dataset

Com s'està tractant un problema que serà tractat amb algorismes de Machine Learning el set de dades que es necessita construir, correspon a un conjunt històric de dades en la que tinguem la informació adient per a que el model sigui capaç d'aprendre a predir el target desitjat.

En aquest tenim l'objectiu de predir corbes d'elasticitat a nivell sku, per tant es necessita que la granularitat del dataset sigui a nivell referència, per tant ens cal un històric de referències que han passat per l'Outlet, amb informació d'aquestes relacionades amb el target que es vol predir.

Com el que es vol, és que s'apregui la relació entre el preu i la venda, el dataset ha de contenir variables relacionades amb la venda i el preu com poden ser descompte, preu inicial, preu actual, mark-up, que correspon al marge de ganància, etc. S'afegeix informació relevant del producte que ens serà útil per a un posterior anàlisi tant de les dades com dels resultats obtinguts.

Quan s'han identificat les dades necessàries per al dataset, es realitza una exploració pel Data Lake, i s'inventiga les taules que es tenen a l'abast i que contenen la informació necessària per a la construcció del nostre dataset, després de realitzar aquesta feina, s'implementa el codi necessari

per a la construcció d'aquest.

Finalment, quan el dataset s'ha creat i està llest per a poder treballar amb la informació que conté, s'escriu dins del bucket de l'squad a s3.

3.2 Anàlisi de les dades

Després de construir i emmagatzemar el dataset a s3, es realitza un breu anàlisi de les dades amb les que es treballa, per a tenir un set de dades que sigui més fàcil treballar reduim tot l'històric construït en el apartat anterior (3.1) i ens quedem amb l'any 2022.

Les figures 2 i 3 mostren la distribució de les ventes durant tot l'any, treballar amb un any d'històric, no afectarà als nostres resultats, ja que es vol predir l'elasticitat al llarg de les promocions d'Outlet i aquestes tenen una durada de 4 setmanes.

A les gràfiques es pot observar que depenent de l'època de l'any en la que ens situem els clients compren un tipus de roba o un altre.

Així com també es capturen amb l'històric de les dades els pics de ventes que corresponen a diferents promocions realitzades com són èpoques de Rebaixes o Black Friday, on tal i com es pot observar en ambdues imatges les ventes incrementen significativament.

Per tant, després d'haver visualitzat aquestes gràfiques i tenir uns coneixements millors sobre les dades construïdes, sabem que el nostre històric capta quan es realitzen els pics de ventes degut a promocions i capta l'estacionalitat, és a dir, la roba que els clients compren depenent de l'època de l'any en la que estem.

Per a poder aprofundir coneixements sobre les dades amb les que es treballarà, a més de les gràfiques que s'han comentat anteriorment, extreiem unes estadístiques sobre aquest dataset com les següents:

- 744.975 observacions amb 21 columnes diferents que ens proporcionen informació.
- Treballem amb un total de 5 temporades diferents.
- Estem treballant amb 17.540 referències diferents.
- A l'outlet veiem 57 preus d'inici diferents.
- Estem treballant amb 13 famílies.

4 MODEL DE MACHINE LEARNING

Per a la realització del treball, s'ha trobat adient treballar amb algorismes de Gradient Boosting [14], algorismes de Machine Learning que es poden utilitzar per a tractar problemes tant de regressió com de classificació.

Més concretament, l'algoritme que es farà servir és el LightGBM [15] [16], que destaca per la seva velocitat, eficiència i capacitat de treballar amb grans conjunts de




Fig. 2: Distribució de la quantitat d'unitats venudes dins de Mango Outlet depenent de la setmana de l'any 2022 segons el tipus de temporada de cada referència.




Fig. 3: Distribució de la quantitat d'unitats venudes dins de Mango Outlet depenent de la setmana de l'any 2022 segons el tipus de família de cada referència.

dades, amb moltes característiques a més a més, destaca pel seu poc temps de resposta tant a l'hora d'entrenar com a l'hora de predir.

Al lightGBM, com a paràmetre es poden passar diversos hiperparàmetres, paràmetres que es fan servir per a controlar el procés d'aprenentatge. Per a trobar aquells que són òptims, es fa servir Optuna [17].

Una de les principals diferències del LightGBM, respecte altres algorismes GBM correspon al creixement dels arbres de decisions que formen el model, en el cas del LightGBM, el creixement és Leaf-wise, com s'observa a la figura 4, que correspon a que a la hora de dividir els nodes, en comptes de dividir-lo per totes les característiques possibles, es selecciona la característica que proporciona la major reducció de la loss function, això permet al LightGBM construir arbres més profunds i precisos.

En canvi, la resta de models GBM presenten un creixement level-wise dels seus arbres de decisions, és a dir, totes les característiques es divideixen alhora.[18]

Abans d'implementar el codi, es miren els avantatges i desavantatges [19] d'aquest model per a tenir-los en compte posteriorment. Alguns dels avantatges del model que es farà servir són els següents:

- Alta velocitat d'entrenament i predicció, el model està dissenyat per ser altament eficient respecte a la velocitat, gràcies a les tècniques que fa servir com la seva estructura dels arbres de decisions i el mostreig de dades




Fig. 4: Arquitectura del LightGBM, algoritme basat en arbres de decisió amb creixement leaf-wise

basat en gradients per a així, poder accelerar el procés de construcció de models. Aquestes optimitzacions permeten al LightGBM que processi ràpidament grans volums de dades i realitzi prediccions amb ràpids temps de resposta.

- Precisió i rendiment superior, LightGBM ha demostrat que pot oferir resultats d'alta precisió i un rendiment competitiu en comparació amb altres algorismes d'aprenentatge automàtic. La seva estructura optimitzada i la seva capacitat per a capturar relacions complexes permeten models més precisos i més robustos.

A més, l'algoritme incorpora tècniques de regularització per a evitar l'overfitting, la qual cosa també és contribueix al model amb la seva precisió

- Capacitat per a treballar amb grans conjunts de dades, l'algoritme és conegut per la seva escalabilitat, gràcies

a les tècniques que fa servir el model està capacitat per a entrenar models amb dades massives sense comprometre la seva precisió.

Pel contrari, aquest algoritme també presenta alguns desavantatges com són els següents:

- La gran capacitat de modelatge que presenta LightGBM es basa en la seva estructura d'arbre de decisió Leaf-wise i la seva manera de treballar que consisteix en minimitzar la funció de loss. Si als arbres sel's permet que creixin sense restriccions o s'ajusten massa a les dades d'entrenament és possible que el model s'ajusti molt als patros apressos durant l'entrenament i no aconsegueixi generalitzar, per tant pot causar overfitting.
- Alta sensibilitat al soroll i dades atípiques: per la seva natura d'expansió per fulles, l'algoritme presenta una tendència a ser més sensible al soroll i dades atípiques respecte altres algoritmes de Gradient Boosting, això es degut a que busca dividir els nodes en funció de reduir la loss, les dades de soroll o les dades poc comunes poden tenir un impacte desproporcionat en aquestes decisions, aquesta sensibilitat pot portar a un alt risc si el dataset conté dades poc comunes o dades amb soroll.
- Major temps de configuració dels hiperparàmetres, paràmetres utilitzats per a controlar el procés d'aprenentatge, ja que l'algoritme ofereix un ampli llistat d'hiperparàmetres amb la finalitat d'ajustar i optimitzar el model. Això presenta més flexibilitat i control sobre el model que s'està implementant però també pot acabar sent un problema degut al temps que s'ha d'invertir per a la configuració adequada d'aquests. Comparant, amb algoritmes més simples amb menys hiperparàmetres la configuració pot ser més complexa i requerir més experimentació addicional per a que els resultats obtinguts siguin els millors.

5 MODELS CONSTRUÏTS

En aquesta secció explicarem els dos tipus de models que s'han implementat per a predir la corba d'elasticitat.

La primera implementació correspon a la construcció d'un model, en el que el target és la venda bruta, per tant haurà de ser capaç de predir la venda de les referències segons el preu amb el que es ven (5.1), en canvi, la segona implementació consisteix a un model, on el target a predir és la variació de l'elasticitat de cada referència respecte a la família a la que pertany (5.2).

5.1 Primer model construït

L'objectiu inicial és predir corbes d'elasticitat a nivell sku, per a realitzar aquesta tasca, s'ha decidit realitzar uns primers models de Machine Learning que consisteixi en predir la venda bruta de cada referència en funció de preus diferents.

Per a realitzar aquesta tasca, com predir la venda bruta és una feina complexa i a més, mai es pot estar segur de les prediccions d'un model, per tant la idea és realitzar un interval per a que els usuaris del model tinguin la decisió final de la predicció realitzada.

Per això implementem una regressió a diferents quantils [20] [21] [22], en aquest cas hem implementat tres models diferents un model de regressió al percentil 5, aquest model abarcarà el 5 per cent de les dades, un altre model de regressió al percentil 95, aquest abarcarà el 95 per cent de les dades, aquests dos models ens donaran com a referència el rail superior i inferior de les prediccions. També, tindrem les prediccions del model al 50 per cent que servirà com a comparatiu.

La primera tasca a realitzar, és dividir el set de dades inicial en dos subconjunts de dades, un primer d'entrenament i un altre de validació, en el de validació agafem 4 setmanes, ja que és el que coneixem que duren les promocions. Un cop dividits es crea una funció que consisteix en entrenar els models a diferents quantils.

En aquest primer entrenament aprofitem per a fer servir oportuna per a trobar els millors hiperparàmetres que farem servir en cadascuna de les execucions del model.

Un cop entrenats els models creem una funció, que realitzi el predict amb el set de test que hem creat prèviament, i calculem el wMAPE (Weighted Mean Absolute Percent Error), que assigna el pes corresponent a cada item depenent del volum de vendes de cadascun d'aquests. Obtenim els següents resultats:

TAULA 1: RESULTATS WMAPE

Quantil 5	Quantil 50	Quantil 95
36%	41%	64%

Les mètriques observades, són les esperades, ja que durant una setmana per a una referència, no és molt comú que hi hagi molta quantitat de vendes per referència, per tant quan estem en un quantil baix, l'error és menor, ja que en proporció preveu que es vendran menys unitats que el que fan els models a quantils superiors.

En aquest model, no ens fixarem gaire en l'error ni el tindrem en compte, ja que l'objectiu és arribar a una corba d'elasticitat fiable. Tot i així, les mètriques obtingudes són semblants a mètriques ja observades en altres projectes de la companyia.

Quan tenim aquesta primera part realitzada, tornem al dataset previ a la separació i es reentrenen els models amb aquest dataset inicial. Al acabar l'entrenament dels models, agafem una mostra nova amb dades de quatre setmanes i sobre aquestes dades es realitza un creuament de totes les referències amb tots els preus disponibles per a l'Outlet i s'eliminen tots aquells escenaris on la referència passa a tenir un preu més elevat que a l'inici del seu cicle de vida dins de l'Outlet i modifiquem variables relacionades amb el preu, ja que el preu ara tindrà un valor diferent.

Un cop tenim aquest dataset preparat, el que realitzem és un predict amb cadascun dels tres models prèviament entrenats. Amb aquests resultats no podem realitzar una validació ja que no tenim el groundtruth del que va passar per a una única referència a més d'un únic preu.

Quan tenim aquests resultats és realitza un processat de les dades per a poder calcular unes corbes d'elasticitat amb aquests resultats, el processat del que parlem consisteix en els següents passos:

1. Juntem tots els resultats en una única taula amb informació adient per al dataset.
2. Decidim l'agregació a la qual volem veure els resultats.
3. Depenent de l'agregació escollida, s'agafa la venda sense descompte d'aquella agregació, ja sigui a nivell família o a nivell referència.
4. Finalment, calculem el ratio del que creix la venda respecte a cada descompte.

Al finalitzar el processat de les dades, ja podem visualitzar les corbes d'elasticitat, calculades. En aquest cas hem triat realitzar el càlcul a nivell de família, per tant realitzem una gràfica per a cadascuna de les famílies disponibles.




Fig. 5: Corbes d'elasticitat als diferents quantils per a la família 10

A les figures 5, 6 i 7 podem veure com a punts dins de les gràfiques les diferents prediccions que ha realitzat el model per a cadascuna de les referències que formen part de la família, en un color blau fosc es pot veure les prediccions que ha realitzat el model al quantil 95, en un color blau cel, el model al quantil 50 i per últim en color verd les del quantil 5.

Pel contrari, les rectes representen la corba d'elasticitat agregada a nivell de la família i és el que analitzarem posteriorment.

S'ha repetit el mateix procés explicat però amb uns quantils 25 i 75, tal i com podem veure a la figura 8, i els ja implementats anteriorment, i s'ha realitzat la gràfica, per a




Fig. 6: Corbes d'elasticitat als diferents quantils per a la família 17




Fig. 7: Corbes d'elasticitat als diferents quantils per a la família 20

poder comparar amb els resultats anteriors, és veu que les observacions del model al quantil 25 són molt semblants al quantil 50.

5.2 Segon model construït

Per al segon model, el que es fa, és canviar el target, per a tenir una altra opció de predir l'elasticitat de les referències. En aquest cas el target, és a dir, la variable que es vol predir, passa a ser la diferència d'elasticitat de les referències respecte l'elasticitat observada de la família a la qual pertanyen.

Per a la realització de la tasca, cal modificar el nostre dataset fins a arribar a tenir la variable que es vol predir, per a aquesta implementació s'han de realitzar alguns càlculs amb variables ja presents dins del set de dades.

Un cop tenim el dataset amb les noves columnes necessàries per a realitzar aquest nou model, tal i com hem realitzat en l'apartat anterior (5.1), dividim aquest set de dades en dos, un d'entrenament i un altre de validació.

A continuació, entrenem una primera versió del model que




Fig. 8: Corbes d'elasticitat per a la família 20 amb cinc quantils diferents

amb l'ajuda d'Optuna buscarem els millors hiperparàmetres per a aquest segon cas. Un cop trobats, es crea una funció d'entrenament on simplement entrenem un model.

Aquest model, l'entrenem fent servir exactament les mateixes features que al model construït anteriorment, això es degut a que quan fem prediccions a futur no li podem proporcionar informació de l'elasticitat de la família per a les futures setmanes, ja que no tindrem aquesta informació.

Quan tinguem el nostre model disponible, el que es realitza és un predict amb les dades que hem separat anteriorment per a la validació i calculem el wMAPE com a mètrica principal. Obtenint com a resultat un 35%.

Tal i com ens ha passat anteriorment, en aquests models de pricing no és tant important el resultat de la mètrica d'error si no, el resultat de l'elasticitat. En aquest model que el que fem és predir directament una diferència entre l'elasticitat general de la família amb la d'una referència en concret, els valors predits són valors que estan en un ordre de magnitud molt baix.

Ara que ja es té un coneixement de que el model està predint valors amb sentit i que s'està còmode treballant amb l'error amb el que es treballarà, tornem a entrenar aquest model amb el dataset inicial, és a dir, aquell que es tenia abans de realitzar el split i amb els hiperparàmetres trobats anteriorment gràcies a Optuna.

Quan es té entrenat aquest model, que entrena amb més històric i per aprendrà més casos diferents i realitzarà una predicció a futur més acurada. Per tant, realitzem un predict amb dades que el model mai ha vist.

Un cop tenim el predict, sabrem com és de diferent la corba d'elasticitat de les referències que formen la família respecte la corba observada d'aquella família.

Per a representar gràficament aquestes corbes noves, el que es realitza és una gràfica amb la corba d'elasticitat observada a nivell família, i es dibuixa un scatter plot on tenim a cada punt del descompte el que es desvien les referències

que formen part d'aquesta família.




Fig. 9: Desviació de l'elasticitat de les referències respecte l'elasticitat de la família 10 observada




Fig. 10: Desviació de l'elasticitat de les referències respecte l'elasticitat de la família 12 observada

Les figures 9, 10 i 11 mostren l'elasticitat observada a la família dins del període en el que es realitzen les prediccions, aquesta elasticitat per família està representada mitjançant la línia de color negra que s'observa a les figures.

En canvi, els punts de color vermell, corresponen a la desviació de l'elasticitat de les referències respecte la família a la que pertanyen, predita fent servir el model implementat als diferents nivells de descompte que es van observar en el període en el qual estem realitzant les prediccions.

6 COMPARACIÓ DE RESULTATS

Un cop tenim implementat les dues alternatives plantejades per a predir l'elasticitat de les referències, procedim a realitzar la comparativa de la feina realitzada.

El primer model, en el que predim la venda bruta a nivell referència al llarg d'una setmana ens beneficia, gràcies als quantils, ja que com veurem al següent apartat (7), tenir la informació de forma visible als diferents quantils pot ser molt útil per part de negoci per determinar les estratègies




Fig. 11: Desviació de l'elasticitat de les referències respecte l'elasticitat de la família 16 observada

a seguir amb les promocions que es vol incorporar de cara al client, ja que d'aquesta manera podrà entendre millor l'actuació futura que farà el comprador.

En canvi, el segon model implementat on es predeix directament la variació de cadascuna de les referències respecte l'elasticitat real observada de la família a la qual pertany, no podem decidir quina serà l'actuació que realitzarà el client quan vagi a comprar a la botiga.

Però gràcies a veure quina és la diferència entre la família i una referència, si que pot ajudar per a saber de cara a determinar una promoció, si hi ha algun producte en concret que no es comportarà com la tendència de la família a la qual pertany.

Per tant, tot i a estar realitzant una previsió de diferents valors, en els dos casos podem acabar visualitzant unes corbes d'elasticitat amb el comportament de la referència i/o agregació desitjada de productes, per a tenir en compte a la hora d'implementar una promoció.

7 ANÀLISI DE LES CORBES

Per a comparar les elasticitats [23] [10] al llarg dels diferents quantils implementats, el que s'ha de realitzar és identificar semblances i/o diferències entre tots els quantils, i mirar aquells casos específics on les elasticitats formen una corba diferent al llarg de tots els quantils.

Comparant les elasticitats a cada quantil es pot entendre la sensibilitat del preu a diferents rangs.

Per a futures optimitzacions, tenint en compte l'elasticitat observada a diferents quantils, per a referències amb alta sensibilitat als quantils baixos són aquelles referències que han de ser considerades per a que entrin a les promocions, rebaxes o campanyes de màrqueting. Pel contrari, amb aquelles referències amb poca sensibilitat als quantils alts, són referències que s'ha de considerar deixar marges alts, ja que es seran venudes sense cap problema.

Per tant els processos a seguir un cop tenim les gràfiques amb les diferents corbes d'elasticitat als diferents quantils amb l'agregació desitjada, per l'analista encarregat de determinar els preus per a una promoció són els següents:

- Identificar aquelles agregacions amb major sensibilitat al preu per als quantils més baixos, això és un indicador que els clients finals responen davant els canvis als preus i per tant, aquesta variació del preu farà que la demanda augmenti. Per tant amb aquests grups de referències és on s'haurien d'aplicar promocions més agressives i realitzar campanyes de marketing sobre aquests items, ja que al promocionar-los davant el client estàs augmentant la possibilitat de compra.
- Mantenir marges més alts per a aquelles agregacions amb una sensibilitat menor al preu en quantils més alts, aquelles referències que mostrin una menor sensibilitat al preu en quantils més alts vol dir que els clients responen menys al canvi de preu per a aquest producte.

Per tant, com el client sabem que comprarà igualment, independent del seu preu, és en aquest cas on s'ha d'aprofitar per a mantenir marges de benefici menys alt, fent que aquestes referències no entrin en promocions, per a justificar aquest fet, es pot seguir una estratègia de màrqueting i posicionar aquests productes com articles de luxe. D'aquesta manera, ens estarem dirigint als clients que estiguin disposats a pagar una quantitat més elevada, pel fet de portar un article d'alta gama.

Quan tenim el cas que l'elasticitat és major a quantils baixos, vol dir que les variacions que tinguin aquestes referències en el preu, tindran un impacte significatiu amb la demanda d'aquests productes, quan aquests productes es trobin amb alts descomptes.

Per tant, abans d'implementar qualsevol tipus de promoció, s'ha de estudiar l'impacte que tindrà i quins són els productes òptims que han d'entrar en la promoció, ja que depenent de la corba d'elasticitat que tinguin aquells productes, s'ha d'aplicar un descompte o un altre, o fins i tot una campanya de publicitat o una altra.

Per l'altra banda, en el segon cas plantejat, on tenim la diferència d'elasticitat d'una referència en concret respecte de la seva família en la qual s'agrega, l'equip de negoci pot prendre decisions potencials respecte possibles promocions a implementar.

Quan tenim el cas que un model dins d'una família molt elàstica és poc elàstic, sabem que aquest model es vendrà molt sense cap tipus de descompte aplicat, per tant possiblement aquest model pot ser exclòs de la promoció planejada.

En canvi, si tenim el cas contrari, que en una família molt elàstica, hi existeix un model molt més elàstic que la família, és en aquest model on s'ha de ficar els descomptes més alts, ja que trigará més en vendre.

Pel contrari, en el cas on tenim famílies poc elàstiques, és a dir, per molt que canviï el preu, la demanda no variarà significativament, com a família seria les famílies que s'hauria d'intentar maximitzar el marge, ja que el client

final comprarà igualment el producte.

Tot i així, si en famílies inelàstiques de cop i volta, hi ha una referència on l'elasticitat creix significativament respecte la família, aquella referència hauria de variar la promoció que se li ha aplicat a la família, i hauria de tenir un descompte més alt, per a poder així, augmentar la demanda final.

Finalment, si tenim famílies poc elàstiques i tenim dins d'aquesta família un producte on l'elasticitat resultant que prediu el model és encara menys elàstica que la de la seva família, aquest model és un clar exemple de models que s'han de promocionar com model especial, i tenir un descompte nul o poc elevat.

Per tant, un estudi de les corbes d'elasticitat que prediu el model és un estudi molt útil per als analistes de pricing, dins del sector del retail, ja que poden extreure conclusions del que passarà en una futura promoció, depenent del nivell de descompte que implementin.

Per afegir, gràcies a un estudi previ de la corba d'elasticitat es poden definir campanyes de màrqueting i publicitat que poden beneficiar a la companyia.

8 PROPER PASSOS

Per a properes iteracions del projecte, s'han de compartir els resultats obtinguts i els anàlisis realitzats amb els analistes de Pricing i els companys dins de Mango que s'encarreguen de l'Outlet per a veure quines són les estratègies a seguir amb aquests nous coneixements adquirits de cara als clients.

Un cop compartits els insights obtinguts, ens agradaria acabar de complementar el forecast realitzat amb una optimització, per a trobar el preu òptim al que s'han d'oferir els productes segons les seves respectives corbes d'elasticitat prèviament calculades, tal com s'ha explicat prèviament en aquest treball.

Per a la realització de la futura optimització, ens agradaria provar mètodes innovadors com és el mètode de Ford-Fulkerson [24], que consisteix en trobar el màxim en una xarxa de fluxe, ja que l'objectiu com a companyia és trobar el preu adient de cadascun dels productes en una promoció que aportin a la companyia el màxim benefici.

A continuació s'adjunta el pseudo-codi:

Tenint com a camí tots els possibles preus que pot tenir una referència de cara al client final i com a node final el benefici total per a la companyia, així doncs, depenent del camí resultant de l'algoritme s'implementaran els preus que portin al camí que té com a resultat els màxims beneficis per a l'Outlet de la companyia.

Per tant, per a poder finalitzar la feina començada, s'hauria d'optimitzar aquelles referències que es consideren potencials per a la promoció, pel contrari aquelles referències

Algorithm 1: Algoritme de Ford-Fulkerson

Entrada: Red de fluxe G , node inicial s , node final t

Sortida : Fluxe màxim

Inicialitzar el fluxe a totes les arestes G a zero;

while *Existeix un camí creixent des de s fins a t en la xarxa residual* **do**

Trobar el camí creixent des de s fins a t en la xarxa residual;

Determinar la capacitat residual mínima c_{min} al llarg del camí creixent;

Actualitzar el fluxe en cada aresta del camí creixent sumant c_{min} a les arestes directes i restant c_{min} a les arestes inverses dins de la xarxa residual;

Càlcul del fluxe màxim sumant els fluxes que surten del node final dins de la xarxa residual;

que per l'elasticitat que presenten es vendria igual, no caldria que entressin dins del procés d'optimització, ja que la millor estratègia seria mantenir preu, per a maximitzar el marge.

9 CONCLUSIONS

Al llarg del projecte s'ha comprovat la importància d'analitzar les corbes d'elasticitat abans d'implementar una promoció dins de la companyia, doncs estudiant l'elasticitat és pot saber quina és la estratègia a seguir per a cadascuna de les promocions, ja que gràcies a aquest estudi, pots saber quines referències són les adients per a promocionar o per mantenir preu.

Dels aprenentatges més importants adquirits és que és important tenir coneixement de l'elasticitat a diferents quantils, ja que a partir d'aquesta informació, podem representar gràficament la corba i extreure noves estratègies que abans no es coneixien.

S'ha après la importància de tenir la variació d'una referència respecte el seu grup de referències, en aquest cas, la família, ja que no sempre tots els productes que formen una família actuaran de la mateixa manera, si no, que hi haurà excepcions que hauran de ser tractades de diferent manera si el que es vol és obtenir els millors resultats.

Per tant, aquest treball ha servit per a aprendre una nova manera de calcular corbes d'elasticitat a nivell referència, a més de les seves possibles aplicacions a nivell de negoci, que estarem implementant dins de Mango.

Un cop finalitzat el treball, ens adonem de la importància que representa tenir aquesta informació a la mínima granularitat possible, en aquest cas el sku, ja que abans d'implementar una promoció, ens podem avançar i prendre decisions a nivell de referència que poden fer millorar el benefici final.

AGRAÏMENTS

Als meus pares i àvies, per haver-me donat el suport necessari per continuar endavant i estar sempre al meu costat.

Volia fer un especial agraïment a Mango, per la gran oportunitat que m'han donat tant d'aprendre com de poder realitzar aquest treball dins de la companyia.

Volia fer una menció especial al Jordi Nadal i al Miquel Tubau que han estat les persones més properes a mi durant aquest any, pel seu suport i tots els coneixements que han compartit amb mi. Gràcies de tot cor!

Per últim, volia donar les gràcies a l'Eduardo, persona que ha tutoritzat aquest treball per part de la universitat i ha estat al meu costat desde el primer dia d'universitat.

REFERÈNCIES

- [1] Mango. Mango. <https://shop.mango.com/es/mujer>, 2023.
- [2] Databricks. Databricks. <https://www.databricks.com>, 2023.
- [3] Amazon. Amazon web services. <https://aws.amazon.com/es/>, 2023.
- [4] Amazon Web Services. Amazon s3. <https://aws.amazon.com/es/s3/>.
- [5] Amazon Web Services. What is a data lake? <https://aws.amazon.com/es/big-data/datalakes-and-analytics/what-is-a-data-lake/>.
- [6] The Apache Software Foundation. Apache airflow. <https://airflow.apache.org>, 2023.
- [7] Jenkins. Jenkins. <https://www.jenkins.io/>, 2023.
- [8] Atlassian. Confluence. <https://www.atlassian.com/es/software/confluence>, 2023.
- [9] Atlassian. Jira. <https://www.atlassian.com/es/software/jira>, 2023.
- [10] Economía 3. Elasticidad de la demanda: qué es y su utilidad. <https://economia3.com/elasticidad-demanda-que-es-utilidad/>, 2023.
- [11] Eleanor Loh, Jalaj Khandelwal, Brian Regan, and Duncan A Little. Prometheus: An end-to-end machine learning framework for optimizing markdown in online fashion e-commerce. In *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pages 3447–3457, 2022.
- [12] Wikipedia contributors. Elasticidad precio de la demanda. https://es.wikipedia.org/wiki/Elasticidad_precio_de_la_demanda, 2023.
- [13] MarketinCloud. La elasticidad de la demanda en el retail. <https://marketincloud.com/la-elasticidad-de-la-demanda-en-el-retail/>.
- [14] Selva Prabhakaran Kumar. An introduction to gradient boosting decision trees. *Machine Learning Plus*, 2023.
- [15] Robert P Sheridan, J Chris Culberson, Elizabeth Joshi, Matthew Tudor, and Prabha Karnachi. Prediction accuracy of production admet models as a function of version: Activity cliffs rule. *Journal of Chemical Information and Modeling*, 62(14):3275–3280, 2022.
- [16] LightGBM Development Team. *LightGBM Documentation*. Microsoft, 2023.
- [17] Takuya Akiba, Shotaro Sano, Takeru Yanase, Toshihiko Ohta, and Masanori Koyama. Optuna. <https://optuna.org>.
- [18] Stack Exchange contributors. Decision trees: Leaf-wise (best-first) and level-wise tree traverse. <https://datascience.stackexchange.com/questions/26699/decision-trees-leaf-wise-best-first-and-level>, 2023.
- [19] Yury Kostylenko. Xgboost vs lightgbm: Which is the best gradient boosting framework? <https://neptune.ai/blog/xgboost-vs-lightgbm>, 2023.
- [20] Shyam Prashant. Lightgbm for quantile regression. *Towards Data Science*, 2023.
- [21] Giancarlo Bonaccorso. Prediction intervals explained: A lightgbm tutorial. *IBM Developer*, 2023.
- [22] Microsoft LightGBM contributors. Lightgbm issue 1036. <https://github.com/microsoft/LightGBM/issues/1036>, 2023.
- [23] Derecho UNED. Interpretación de la elasticidad precio de la demanda. <https://derechouned.com/libro/economia/7455-interpretacion-de-la-elasticidad-precio~:text=La%20elasticidad%20precio%20de%20la%20demanda%20indica%20c%C3%B3mo%20var%C3%ADa%20el,no%20modifica%20el%20ingreso%20total.,> 2023.
- [24] Wikipedia contributors. Ford-fulkerson algorithm. https://en.wikipedia.org/wiki/Ford%E2%80%93Fulkerson_algorithm, 2023.