

UNIVERSITATEA TEHNICĂ “GHEORGHE ASACHI”
DIN IAŞI



DECISION INTELLIGENCE FRAMEWORK FOR PREDICTING PURCHASE INTENTIONS IN E-COMMERCE

(PLATFORMĂ DE INTELIGENȚĂ DECIZIONALĂ PENTRU PREDICȚIA INTENȚIILOR DE CUMPĂRARE ÎN COMERȚUL ONLINE)

Ing. Alexandru Grigoraș

Conducător de doctorat: Prof. dr. ing. Florin Leon

Iași, 2026

DECISION INTELLIGENCE FRAMEWORK FOR PREDICTING PURCHASE INTENTIONS IN E-COMMERCE

(PLATFORMĂ DE INTELIGENȚĂ DECIZIONALĂ PENTRU PREDICȚIA INTENȚIILOR DE CUMPĂRARE ÎN COMERȚUL ONLINE)

Alexandru Grigoraș

Domeniul: Calculatoare și Tehnologia Informației

Președinte comisie doctorat:	Prof. dr. ing. Adrian Burlacu
Conducător de doctorat:	Prof. dr. ing. Florin Leon
Referenți oficiali:	Prof. dr. inf. Lenuța Alboaie
	Prof. dr. ing. Ovidiu Schipor
	Prof. dr. ing. Adrian Alexandrescu
Comisia de îndrumare și integritate academică:	Prof. dr. ing. Petru Cașcaval
	Conf. dr. Mădălina Răschip
	Conf. dr. ing. Marius Gavrilescu

CUPRINS

CAPITOLUL 1. INTRODUCERE 1

1.1. Contextul cercetării și motivația 1

1.2. Problema de cercetare și provocările abordate 2

1.3. Obiectivele și întrebările de cercetare 2

1.4. Contribuțiile originale ale tezei 3

1.5. Structura tezei 4

CAPITOLUL 2. FUNDAMENTE ALE INTELIGENȚEI DECIZIONALE ȘI ALE MODELĂRII PREDICTIVE 5

2.1. Concepte ale inteligenței decizionale 5

2.2. Modelarea predictivă a comportamentului clienților 5

2.3. Metode de generare a datelor sintetice 5

2.4. Analiza scenariilor de tip „ce se întâmplă dacă” 6

2.5. Explicabilitatea sistemelor decizionale 6

2.6. Lacunele cercetării existente 7

CAPITOLUL 3. DATE ȘI ANALIZĂ COMPORTAMENTALĂ ÎN COMERȚUL ONLINE 8

3.1. Seturi de date și reprezentări utilizate 8

3.2. Regimuri ale seriilor de timp în comerțul online 8

3.3. Indicatori comportamentali ai intenției de cumpărare 8

3.4. Preprocesarea datelor 9

3.5. Partiționarea cronologică a datelor 9

CAPITOLUL 4. COMPONENTELE DE MODELARE ALE FRAMEWORK-ULUI DE INTELIGENȚĂ DECIZIONALĂ 11

4.1. Structura generală a framework-ului 11

4.2. Formularea framework-ului DIF-PI 12

4.3. Modulul NPD pentru predicția următoarei zile de cumpărare 13

4.4. Modulul SDG pentru generarea seriilor de timp sintetice 13

4.5. Modulul TBWISA pentru analiza scenariilor de preț 14

4.6. Modelul global Transformer pentru predicția cererii 16

4.7. Determinarea ferestrei optime de venit 16

4.8. Modulul X-TBWISA pentru explicabilitate și filtrare 17

CAPITOLUL 5. PIPELINE-UL DIF-PI ȘI ARHITECTURA SOFTWARE 19

5.1. Arhitectura generală 19

5.2. Integrarea modulelor în framework-ul DIF-PI 19

5.3. Reproductibilitatea și structura implementării software 20

5.4. Protocolul studiilor de caz și aplicații practice 20

CAPITOLUL 6. EVALUARE 22

6.1. Metodologia experimentală 22

6.2. Validarea modulului NPD 22

6.3. Validarea modulului SDG 23

6.4. Validarea modulului TBWISA 24
6.5. Validarea modulului X-TBWISA 25
6.6. Evaluarea integrată a framework-ului DIF-PI 26
6.7. Analiza de ablație 27
6.8. Discuții, limitări și semnificație managerială 27
CAPITOLUL 7. CONCLUZII 29
7.1. Sinteza rezultatelor obținute 29
7.2. Contribuțiile principale ale tezei 29
7.3. Limitări și considerații privind validitatea 30
7.4. Direcții viitoare de cercetare 30
BIBLIOGRAFIE 31
LISTA LUCRĂRILOR PUBLICATE 33

REZUMAT

Teza de doctorat abordează proiectarea, implementarea și evaluarea unui framework de inteligență decizională pentru predicția intenției de cumpărare a consumatorilor în comerțul online și susținerea deciziilor de ajustare a prețului și a promoțiilor. Platformele de comerț online generează volume mari de date tranzacționale și comportamentale, acestea fiind utilizate frecvent pentru raportare, dashboard-uri sau antrenarea modelelor predictive. Aceste instrumente pot descrie trecutul și pot estima evoluțiile viitoare, dar nu răspund la întrebările operaționale: ce acțiune trebuie aplicată, când trebuie aplicată și cât de fiabilă este recomandarea generată.

Pentru a aborda această problemă, teza propune DIF-PI (Decision Intelligence Framework for Predicting Purchase Intentions), un framework de inteligență decizională care combină predicția intenției de cumpărare, generarea de date sintetice, predicția cererii produselor, analiza de scenarii de tip „ce se întâmplă dacă", determinarea ferestrei optime de venit și filtrarea bazată pe metode de explicabilitate. Framework-ul propus tratează intenția de cumpărare pe două niveluri complementare. La nivel de client, intenția este modelată ca o problemă temporală prin istoricul tranzacțiilor, intervalele dintre cumpărări succesive și predicția următoarei zile de cumpărare. La nivel de produs, intenția este analizată indirect prin cererea zilnică, răspunsul la modificările de preț și venitul estimat în scenarii alternative.

Din punct de vedere metodologic, teza combină mai multe componente. Modulul NPD (Next Purchase Day) folosește un model de predicție de tip Transformer pentru a estima momentul următoarei achiziții. Modulul SDG (Synthetic Data Generation) este bazat pe LLM-uri (Large Language Models) și utilizează generarea de serii de timp sintetice pentru a susține robustețea în regimuri cu date scurte sau incomplete. Modulul TBWISA combină modelul structural cauzal, estimarea controlată a elasticității, simularea stocastică, predicțiile realizate de modelul Transformer și selecția intervalului optim de venit. X-TBWISA adaugă un strat de explicabilitate și filtrare decizională, folosind un model surogat XGBoost, explicații TreeSHAP, stabilitatea atribuțiilor și verificări de plauzibilitate economică.

Evaluarea este realizată pe trei niveluri: validarea componentelor individuale, studiu de caz pe trei regimuri reprezentative de produse și analiza de ablație pentru evaluarea contribuției componentelor. Rezultatele indică erori mai mici pentru modelele Transformer față de modelele de referință în sarcinile de predicție a cererii produselor. Modulul SDG poate susține analiza în situații de date incomplete, frecvent întâlnite în sistemele existente. TBWISA produce scenarii mai stabile și mai plauzibile economic decât modele de referință, iar X-TBWISA oferă un mecanism de filtrare a recomandărilor prin etichetarea recomandărilor ca *Accept*, *Accept Caution* sau *Flag*.

Contribuția principală a tezei constă în definirea framework-ului DIF-PI, care transformă datele din comerțul online în recomandări de preț structurate, optimizate și validate. Rezultatul nu este o decizie automată care înlocuiește managerul, ci un obiect decizional care conține intervenția de preț recomandată, fereastra de aplicare, creșterea estimată, scorul decizional, statusul de filtrare și informațiile de suport necesare pentru analiza recomandării. Prin această abordare, DIF-PI sprijină analiza deciziilor de ajustare a prețului contribuind la un proces decizional mai transparent, reproductibil și ușor de analizat.

CAPITOLUL 1. INTRODUCERE

1.1. Contextul cercetării și motivația

Comerțul electronic generează volume mari de date despre interacțiunile dintre clienți, produse, prețuri și promoții. Platformele digitale pot înregistra căutările utilizatorilor, vizualizări ale produselor, coșurile de cumpărături, achizițiile, reacțiile la campanii dar și modificările de preț. Aceste date pot susține recomandările personalizate, predicția vânzărilor și analiza comportamentală a consumatorilor, însă simpla lor disponibilitate nu conduce automat la decizii mai bune [1].

În multe organizații, datele sunt folosite mai ales pentru raportare și analiză prin dashboard-uri sau pentru antrenarea modelelor predictive. Aceste instrumente pot analiza date istorice sau pot estima evoluțiile viitoare, însă nu răspund întotdeauna la întrebările operaționale ale unui manager: ce acțiune trebuie aplicată, când trebuie aplicată, cât timp trebuie menținută și cât de fiabilă este recomandarea generată [2], [3]. Această problemă este importantă în luarea deciziilor de ajustare a prețului produselor și crearea promoțiilor pentru optimizarea stocului. Predicția cererii nu este suficientă dacă nu este transformată într-o recomandare operațională. Managerul trebuie să poată evalua dacă o reducere sau o majorare de preț este oportună, ce impact poate avea asupra venitului, în ce interval ar trebui aplicată și dacă scenariul este plauzibil din punct de vedere economic.

Inteligența decizională (DI) oferă un framework potrivit pentru această direcție deoarece pornește de la obiectivul decizional și combină datele, modelele predictive, simulările, optimizarea și mecanismele de validare într-un framework orientat spre acțiuni concrete [4], [5]. În această teză, Inteligența decizională este utilizată pentru a susține deciziile de intervenții asupra prețului în comerțul online prin determinarea intenției de cumpărare și analiza scenariilor alternative de preț. Această logică este sintetizată în Figura 1, unde procesul de inteligență decizională este reprezentat ca un framework iterativ: obiectivul decizional este definit, problema este formulată, sunt simulate și evaluate alternativele, iar rezultatul este monitorizat pentru a îmbunătăți deciziile viitoare.

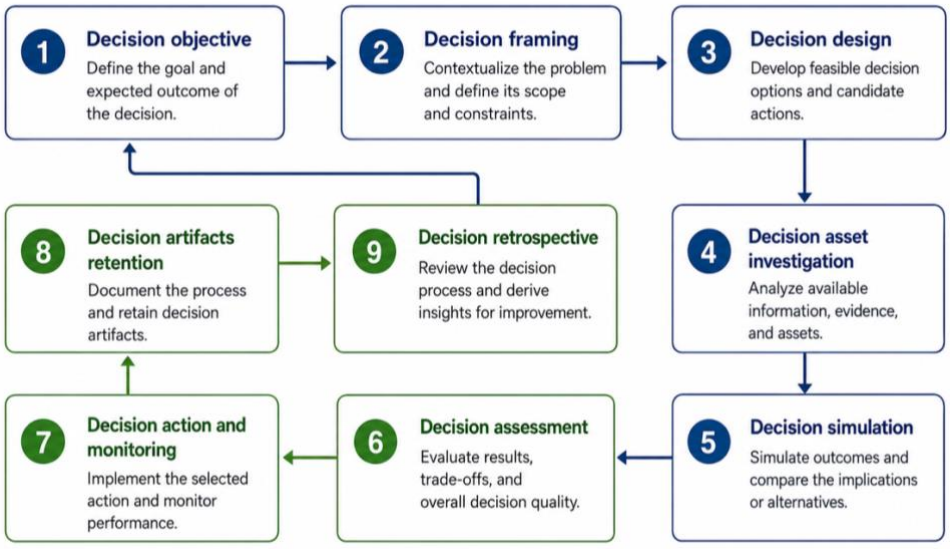

Figura 1. Procesul de Inteligență Decizională, adaptat din [4]

Motivația tezei pornește de la faptul că performanța tehnică a unui model nu garantează utilitatea sa decizională. Un model poate avea rezultate bune într-o evaluare experimentală, dar poate fi insuficient pentru un manager dacă nu produce o recomandare formulată operațional. DIF-PI este propus pentru a reduce această diferență dintre predicție și decizie, printr-un rezultat care include intervenția de preț, perioada de aplicare, impactul estimat și gradul de prudență asociat recomandării.

1.2. Problema de cercetare și provocările abordate

Problema centrală a tezei este proiectarea unui framework integrat de Inteligență Decizională care să prezică intenția de cumpărare și să susțină deciziile de preț prin evaluarea unor scenarii alternative într-un mod plauzibil, robust și coerent economic.

Aceasta combină trei direcții: predicția, simularea intervențiilor și optimizarea deciziei. Predicția răspunde la întrebarea *„ce este probabil să se întâmple?”*, simularea scenariilor răspunde la întrebarea *„ce s-ar putea întâmpla dacă se modifică prețul?”* iar optimizarea răspunde la întrebarea *„care alternativă este mai potrivită pentru obiectivul urmărit?”*. În DIF-PI, aceste etape sunt conectate într-un pipeline unificat, iar rezultatul final este verificat printr-un strat de explicabilitate și filtrare decizională [4], [6].

Provocările abordate sunt legate de diversitatea comportamentului de cumpărare al consumatorilor, de caracterul neregulat al cererii și de calitatea variabilă a datelor disponibile. Clienții nu cumpără în același ritm, nu au aceeași regularitate, iar produsele nu prezintă aceeași densitate a cererii. Unele produse au un istoric lung și stabil al cererii, în timp ce altele au cerere intermitentă sau multe zile fără vânzări. Indicatorii agregați pot ascunde astfel diferențe importante între segmente și pot conduce la estimări mai puțin fiabile [1], [3]. Istoricele produselor sau clienților pot fi scurte ori pot conține date eronate sau incomplete, iar utilizarea datelor la nivel de client poate fi limitată de cerințele de confidențialitate. Aceste aspecte justifică includerea unui modul de generare de serii de timp sintetice care este utilizat ca suport pentru a crește robustețea analizei [7], [8], [9].

O altă dificultate este diferența dintre predicție și intervenție. Un model de predicție a valorilor viitoare estimează evoluția probabilă a cererii pe baza trecutului, în timp ce o decizie de preț presupune estimarea unui rezultat sub o intervenție ipotetică, la care nu există date reale. Aceasta transformă problema într-o analiză de scenarii de tip *„ce se întâmplă dacă”*, în care relația dintre preț și cerere trebuie interpretată împreună cu elasticitatea, incertitudinea și plauzibilitatea economică [10], [11], [12]. Un sistem decizional nu trebuie să ofere doar alternativa cu scorul numeric maxim, ci și informații despre stabilitatea, plauzibilitatea și riscul recomandării. Această nevoie justifică introducerea componentei X-TBWISA, care folosește explicabilitatea ca mecanism de diagnosticare și filtrare decizională [6], [13], [14].

1.3. Obiectivele și întrebările de cercetare

Scopul tezei este de a proiecta, implementa și evalua un framework de inteligență decizională care combină generarea de serii de timp sintetice, modelul de tip Transformer pentru predicția intenției de cumpărare și analiza de scenarii de tip „ce se întâmplă dacă”, cu obiectivul de a susține deciziile de preț și crearea promoțiilor în comerțul online [6], [9], [12], [15].

Teza tratează modulele NPD, SDG, TBWISA și X-TBWISA ca părți ale unui pipeline decizional. NPD oferă un semnal temporal privind comportamentul de cumpărare, SDG susține analiza în regimuri cu date scurte sau incomplete, TBWISA generează scenarii ipotetice de preț, iar X-TBWISA adaugă explicabilitate și filtrare decizională pentru manageri.

Pentru a păstra legătura dintre obiectivele metodologice și întrebările de cercetare, Tabelul 1 prezintă corespondența dintre cele cinci obiective ale tezei și întrebările asociate. Aceste obiective urmăresc trecerea de la analiza comportamentului de cumpărare la construirea unui framework decizional complet. Primele trei obiective susțin partea predictivă și de generare a datelor, iar ultimele două analizează scenariile de preț, integrarea modulelor și evaluarea DIF-PI.

Tabelul 1. Obiectivele și întrebările de cercetare ale tezei

Obiectiv	***Întrebare de cercetare asociată***
O1. *Caracterizare comportamentală*	**RQ1.** Cum poate fi modelat comportamentul de cumpărare atunci când datele sunt limitate, incomplete sau variate de la un client la altul?
O2. *Generare de serii de timp sintetice*	**RQ2.** În ce măsură pot seriile de timp sintetice generate de modele de tip LLM să susțină predicția și analiza scenariilor ipotetice?
O3. *Predicția cererii cu un model de tip Transformer*	**RQ3.** Cât de bine funcționează modelele Transformer față de metodele clasice și alte modele de învățare profundă pentru predicția intenției de cumpărare și a cererii?
O4. *Generarea scenariilor și identificarea ferestrei de venit*	**RQ4.** Cum pot fi combinate estimarea elasticității, modelul structural cauzal și predicția seriilor de timp pentru a genera scenarii de preț plauzibile economic?
O5. *Integrarea și evaluarea pipeline-ului*	**RQ5.** Ce soluții arhitecturale permit integrarea generării de date sintetice, a predicției cererii, a scenariilor de preț și a validării deciziilor în DIF-PI?

1.4. Contribuțiile originale ale tezei

Contribuția principală a tezei este definirea DIF-PI, un framework de inteligență decizională pentru predicția intenției de cumpărare și susținerea deciziilor de schimbare a prețului în comerțul online. Acesta combină predicția comportamentală, generarea de serii de timp sintetice, analiza scenariilor de preț, predicția cererii, optimizarea ferestrei de venit și filtrarea prin explicabilitate. Prin această integrare, teza propune trecerea de la modele predictive izolate la un pipeline decizional orientat spre recomandări structurate și verificabile.

La nivel metodologic, teza integrează modulul NPD, bazat pe modele Transformer pentru predicția următoarei zile de cumpărare a consumatorilor. Modulul transformă istoricul tranzacțional al clienților în secvențe de intervale dintre cumpărări și estimează momentul probabil al unei achiziții viitoare. În DIF-PI, NPD este utilizat ca semnal temporal de intenție [15].

O altă contribuție este includerea modulului SDG pentru generarea de serii de timp sintetice. Acesta susține analiza în situațiile în care istoricul de tranzacții este scurt, incomplet sau sensibil din punctul de vedere al confidențialității. Modulul este evaluat prin fidelitate, utilitate și confidențialitate, ceea ce permite o interpretare echilibrată a beneficiilor și limitărilor generării sintetice [9].

Teza formalizează și integrează TBWISA ca generator de scenarii ipotetice de preț. TBWISA combină modelarea cauzală structurală, estimarea controlată a elasticității, ajustarea neliniară a răspunsului la preț, simularea stocastică, predicția cu modelul Transformer și optimizarea ferestrei de venit. Framework-ul evaluează alternativele de preț prin combinarea continuității istorice a cererii cu scenarii ipotetice ale prețului [12].

Componenta X-TBWISA completează acest pipeline printr-un strat de explicabilitate și filtrare decizională aplicat peste scenariile TBWISA. X-TBWISA utilizează un model surogat XGBoost și explicații TreeSHAP pentru a analiza stabilitatea locală a scenariilor, plauzibilitatea economică și riscul recomandărilor. Explicațiile sunt tratate ca instrumente diagnostice pentru guvernanță și validarea deciziilor [6], [13], [14].

Teza contribuie și prin evaluarea framework-ului propus. Aceasta include validarea individuală a modulelor propuse, studii de caz pe trei regimuri diferite de produse și o analiză de ablație pentru determinarea componentelor cele mai importante. Evaluarea arată modul în care componentele contribuie la calitatea recomandării finale, la stabilitatea ferestrei de venit și la interpretarea managerială a rezultatului.

1.5. Structura tezei

Teza este organizată în șapte capitole:

- *Capitolul 1* prezintă contextul cercetării, problema abordată, obiectivele, întrebările de cercetare și contribuțiile originale;
- *Capitolul 2* discută fundamentele inteligenței decizionale, modelarea predictivă a comportamentului clienților, generarea de date sintetice, analiza de scenarii de tip *„ce se întâmplă dacă”*, modelarea elasticității și explicabilitatea sistemelor decizionale;
- *Capitolul 3* descrie datele utilizate, reprezentările tranzacționale și cele la nivel zilnic ale produselor, indicatorii comportamentali și regulile de preprocesare;
- *Capitolul 4* prezintă componentele principale ale framework-ului DIF-PI: NPD, SDG, TBWISA, modelul global Transformer, optimizarea ferestrei de venit și X-TBWISA;
- *Capitolul 5* descrie pipeline-ul DIF-PI și arhitectura software, evidențiind modul în care componentele sunt conectate într-o implementare reproductibilă;
- *Capitolul 6* prezintă evaluarea framework-ului propus, incluzând validarea modulelor, evaluarea integrată pe studii de caz și analiza de ablație;
- *Capitolul 7* sintetizează rezultatele, răspunde întrebărilor de cercetare, discută limitările și indică direcțiile viitoare de cercetare.

CAPITOLUL 2. FUNDAMENTE ALE INTELIGENȚEI DECIZIONALE ȘI ALE MODELĂRII PREDICTIVE

2.1. Concepte ale inteligenței decizionale

Inteligența decizională conectează datele, modelele predictive, modelarea cauzală, simularea, optimizarea și procesele umane de luare a deciziilor. Spre deosebire de analiza descriptivă, care explică ce s-a întâmplat, sau de analiza predictivă, care estimează ce se poate întâmpla, DI urmărește să sprijine alegerea unei acțiuni sau intervenții [4], [5].

În contextul comerțului electronic, această distincție este importantă. Un manager nu are nevoie doar de predicția cererii, ci de o recomandare care poate fi analizată într-un context operațional: ce modificare de preț este justificată, când ar trebui aplicată, cât timp trebuie menținută și ce riscuri sunt asociate scenariului. Un framework de inteligență decizională trebuie să combine predicția, analiza scenariilor, optimizarea, explicabilitatea și verificarea recomandărilor.

Business Intelligence (BI) se concentrează pe rapoarte, indicatori și dashboard-uri, în timp ce inteligența decizională este orientată spre alegerea unei acțiuni. Față de un sistem strict predictiv, aceasta introduce scenarii alternative și criterii de selecție, iar față de o abordare strict prescriptivă adaugă mecanisme de verificare, explicabilitate și control al riscului. Această abordare justifică structura framework-ului DIF-PI, care nu se oprește la predicția comportamentului de cumpărare sau la predicția cererii, ci continuă cu simularea intervențiilor de preț, optimizarea ferestrei de venit și filtrarea decizională a recomandărilor [6], [9], [12], [15].

2.2. Modelarea predictivă a comportamentului clienților

Modelarea comportamentului clienților este relevantă în retail și comerț online deoarece susține predicția activității viitoare: dacă un client va mai cumpăra, când va cumpăra și cât de regulat este comportamentul său. Pentru clienții fără abonament sau contract activ, istoricul tranzacțiilor poate fi analizat prin recență, frecvență, valoare monetară și regularitatea cumpărărilor. Modele clasice precum Pareto/NBD și BG/NBD au arătat că aceste informații pot fi tratate ca semnale temporale ale comportamentului viitor [16], [17].

În datele reale, comportamentul clienților diferă considerabil de la un client la altul. Unii clienți cumpără frecvent și relativ regulat, în timp ce alții cumpără rar sau imprevizibil. Un singur indicator agregat nu poate descrie suficient de bine intenția de cumpărare. În teză, intenția de cumpărare este tratată pe două niveluri: la nivel de client, prin succesiunea intervalelor dintre cumpărări și la nivel de produs prin cerere, răspuns la preț și venit estimat sub scenariile alternative.

Modelele Transformer sunt relevante deoarece mecanismul de *self-attention* poate identifica relații temporale pe termen scurt și pe termen mai lung. Pentru NPD, modelul învață din secvențe de intervale dintre cumpărări și estimează următorul moment probabil de achiziție. Pentru predicția cererii, modelul Transformer estimează cum poate evolua cererea în perioada analizată pentru fiecare scenariu de preț. În teză, modelele Transformer sunt folosite deoarece sunt potrivite pentru sarcini secvențiale în care ordinea temporală și relațiile dintre observații influențează calitatea predicției, cum este cazul predicției următoarei zile de cumpărare și al predicției cererii [15], [18], [19].

2.3. Metode de generare a datelor sintetice

Generarea datelor sintetice urmărește producerea unor date artificiale care păstrează proprietățile statistice relevante ale datelor reale. În comerțul online, această direcție este importantă deoarece multe produse au istorii scurte, multe serii de timp sunt intermitente, iar datele la nivel de client pot fi sensibile. Datele sintetice nu garantează automat nici utilitate, nici confidențialitate. Utilitatea lor trebuie evaluată în raport cu scopul decizional pentru care sunt folosite [7], [8].

Pentru seriile de timp, generarea sintetică este mai dificilă decât pentru datele tabelare simple, deoarece trebuie păstrate dependențele în timp, sezonalitatea, trendul, autocorelațiile și structura valorilor nule sau intermitente. Modulul SDG tratează seriile de timp ca secvențe de tokeni numerici. Valorile sunt scalate, cuantizate și transformate într-un vocabular discret, astfel încât un model de tip encoder-decoder să poată genera o continuare sintetică a seriei [9], [20].

În DIF-PI, modulul SDG are un rol de suport: datele sintetice nu înlocuiesc datele reale în evaluarea finală și nu sunt prezentate ca soluție universală pentru toate problemele de date. Ele sunt utilizate pentru creșterea robusteții, pentru extinderea unor istorii scurte, pentru repararea unor segmente incomplete și pentru analiza regimurilor cu date slabe. Evaluarea modulului este realizată pe trei dimensiuni: fidelitate, utilitate și confidențialitate, deoarece un generator poate avea performanțe bune pe o dimensiune și mai slabe pe alta [7], [8], [9].

2.4. Analiza scenariilor de tip „ce se întâmplă dacă”

Analiza scenariilor de tip „ce se întâmplă dacă” estimează cum se poate modifica un rezultat atunci când una sau mai multe variabile de intrare sunt schimbate. În deciziile de preț, întrebarea centrală este ce se poate întâmpla cu cererea și venitul dacă prețul este redus sau majorat cu un procent stabilit. Această întrebare nu urmărește doar evoluția probabilă a cererii, ci și efectul posibil al unei intervenții ipotetice asupra prețului [21].

Analiza scenariilor este operaționalizată prin TBWISA, care combină modelarea cauzală structurală, estimarea elasticității, simularea stocastică și predicția cu modelul de tip Transformer [11], [12]. Elasticitatea cererii în funcție de preț este indicatorul economic folosit pentru a exprima sensibilitatea cererii la modificările de preț. În mod obișnuit, pentru multe produse de retail se așteaptă ca cererea să scadă atunci când prețul crește și să crească atunci când prețul scade, dacă ceilalți factori rămân constanți [10], [22].

Această relație nu este însă tratată ca adevăr universal. Datele comerciale sunt observaționale, iar prețurile istorice pot fi influențate de sezonalitate, campanii de promovare, stoc, concurență sau strategii comerciale. Relația negativă dintre preț și cerere este folosită ca regulă de plauzibilitate economică. Scenariile generate de TBWISA trebuie interpretate ca simulări informate structural, nu ca efecte cauzale complet identificate.

Prin această abordare, framework-ul nu este limitat la predicția cererii în condițiile existente, ci poate compara mai multe intervenții de preț și poate selecta intervalul de aplicare cu scor favorabil.

2.5. Explicabilitatea sistemelor decizionale

Explicabilitatea este importantă într-un sistem de suport decizional deoarece recomandările trebuie să poată fi discutate, verificate și revizuite. În ajustările de preț și în crearea promoțiilor, nu este suficientă obținerea unui scor numeric favorabil. Managerul trebuie să poată verifica stabilitatea recomandării, plauzibilitatea ei economică și necesitatea unei analize suplimentare [4], [6].

Modelele de predicție bazate pe rețele neuronale pot avea performanțe bune, dar sunt dificil de interpretat. Atunci când sunt folosite în scenarii de intervenție, ele pot evalua situații diferite de cele observate istoric. Din acest motiv, teza introduce X-TBWISA ca strat de explicabilitate și filtrare decizională. Componenta folosește un model surogat XGBoost, antrenat pentru a aproxima ieșirile modelului de predicție, iar pentru acest surogat sunt calculate explicații TreeSHAP [6], [13], [14].

Explicațiile sunt utilizate ca instrumente de diagnosticare. Atribuțiile SHAP nu indică efectul cauzal real al unei intervenții de preț, ci descriu comportamentul modelului surogat. În X-TBWISA, aceste explicații sunt folosite pentru a verifica stabilitatea între intervenții apropiate, concentrarea contribuțiilor pe caracteristici legate de preț și alinierea scenariului cu reguli de plauzibilitate economică. Recomandările sunt marcate printr-un status: *Accept*, *Accept Caution* sau *Flag*.

2.6. Lacunele cercetării existente

Literatura analizată acoperă direcții relevante pentru teză: predicția comportamentului clienților, predicția cererii, generarea datelor sintetice, analiza scenariilor și explicabilitatea modelelor. Aceste direcții sunt adesea tratate separat și sunt rareori reunite într-un pipeline decizional integrat orientat către decizii concrete de preț și promoție în comerțul electronic [4], [5], [6].

O primă lacună este separarea dintre predicție și suport decizional. Multe studii estimează probabilitatea de cumpărare, următoarea achiziție sau cererea viitoare, dar nu arată suficient de clar cum poate fi folosită această estimare pentru a alege o acțiune [1], [16], [18]. Generarea datelor sintetice este evaluată frecvent prin fidelitate sau utilitate predictivă, dar mai rar este analizată în cadrul unui sistem complet de decizie, unde trebuie observat dacă datele sintetice susțin sau afectează calitatea recomandărilor [7], [8], [9].

O altă lacună privește plauzibilitatea economică a scenariilor generate de modelele de învățare automată. Modelele de tip black-box pot obține rezultate bune în medie, dar pot produce răspunsuri nerealiste sub intervenții de preț dacă nu sunt verificate prin reguli economice și diagnostice de stabilitate [10], [11], [12]. Explicabilitatea este folosită adesea doar descriptiv, după generarea rezultatului. În această teză, ea este integrată ca mecanism de diagnosticare și filtrare decizională prin modulul X-TBWISA [6], [13], [14].

CAPITOLUL 3. DATE ȘI ANALIZĂ COMPORTAMENTALĂ ÎN COMERȚUL ONLINE

3.1. Seturi de date și reprezentări utilizate

Capitolul 3 prezintă datele utilizate pentru construirea și evaluarea framework-ului DIF-PI. Datele provin din contexte de retail și comerț online și sunt organizate pe două niveluri de analiză complementare: comportamentul de cumpărare la nivel de client și cererea agregată la nivel de produs. Această separare este necesară deoarece intenția de cumpărare a unui client și cererea zilnică a unui produs nu surprind același nivel al fenomenului analizat, chiar dacă provin din același sistem comercial [12], [15], [23].

La nivel de client, analiza se bazează pe istoricul tranzacțiilor, frecvența achizițiilor, recență și intervalele dintre cumpărări. Această reprezentare este utilizată de modulul NPD, care estimează următoarea zi de cumpărare. La nivel de produs, analiza se bazează pe cererea zilnică, prețul zilnic și variațiile acestora în timp, fiind utilizată de SDG, TBWISA, modelul global de predicție și evaluarea integrată DIF-PI. Aceste două perspective sunt aliniate printr-un tabel tranzacțional și un set de date zilnice la nivel de SKU. Un SKU este o unitate de stoc sau produs individual urmărit în sistemul de retail. Tabelul tranzacțional păstrează evenimentele de cumpărare, iar setul de date zilnice le agregă într-o serie de timp de tip preț-cerere. Această separare este sintetizată în Tabelul 2.

Tabelul 2. Reprezentările de date utilizate în DIF-PI

Reprezentare	***Unitate de analiză***	***Rol în DIF-PI***
Tabel tranzacțional	Eveniment de cumpărare / client	NPD și analiză comportamentală
Tabel zilnic SKU	Produs-zi	SDG, TBWISA, predicție și evaluare integrată
Metadate de eligibilitate	SKU	Filtrare, selecția cazurilor și interpretarea regimurilor

3.2. Regimuri ale seriilor de timp în comerțul online

Seriile de timp din retail sunt foarte diferite între ele. Unele produse au cerere constantă, altele au multe zile fără vânzări, iar unele prezintă o relație vizibilă între schimbările de preț și variațiile cererii. Teza nu tratează toate SKU-urile ca fiind echivalente, ci folosește indicatori care descriu regimul seriei de timp și gradul de informație disponibil pentru predicție și scenarii [12], [23].

Indicatorii principali sunt proporția zilelor active, proporția zilelor fără vânzări, numărul de zile active, lungimea istoricului și comportamentul schimbărilor de preț. O proporție mare a zilelor active indică o serie mai densă și mai informativă pentru predicție, în timp ce o proporție mare a zilelor fără vânzări indică o serie intermitentă, pentru care rezultatele trebuie interpretate cu mai multă prudență.

Acești indicatori nu au doar rol descriptiv. Ei influențează eligibilitatea SKU-urilor pentru antrenare, selecția cazurilor de evaluare și interpretarea rezultatelor integrate. Modelul global de predicție de tip Transformer are nevoie de istorii suficient de lungi și informative, TBWISA are nevoie de o relație preț-cerere care poate fi estimată rezonabil, iar SDG devine mai relevant atunci când seriile sunt scurte, rare sau incomplete [9], [12], [23].

3.3. Indicatori comportamentali ai intenției de cumpărare

La nivel de client, intenția de cumpărare a consumatorilor este descrisă prin indicatori calculați din istoricul tranzacțiilor. Cei mai importanți sunt indicatorii de recență, frecvență, valoare monetară, intervalul mediu dintre cumpărări, variabilitatea acestor intervale și numărul de zile active [24], [25]. Indicatorul central pentru modulul NPD este intervalul dintre cumpărări. Pentru fiecare client, achizițiile sunt ordonate cronologic, iar diferențele dintre două achiziții consecutive formează o

secvență temporală. Modelul NPD folosește această secvență pentru a estima următorul interval până la cumpărare. Această formulare păstrează ordinea temporală a comportamentului și transformă istoricul tranzacțional într-o problemă de predicție temporală [15], [17].

Teza utilizează și indicatori de regularitate. Coeficientul de variație al intervalelor dintre cumpărări arată cât de stabil este ritmul de cumpărare al unui client. Clienții cu intervale mai regulate oferă un semnal temporal mai clar, în timp ce clienții cu activitate rară sau neregulată sunt mai dificil de modelat. Din acest motiv, performanța modulului NPD trebuie interpretată și în funcție de segmentele comportamentale, nu doar printr-o medie globală [15].

La nivel de produs, acești indicatori sunt completați de indicatori de cerere și preț, precum cererea zilnică, prețul zilnic, modificările de preț și proporția zilelor fără vânzări. Acești indicatori descriu regimul seriei SKU și arată dacă produsul are o cerere suficient de densă, dacă este intermitent sau dacă există variații de preț utile pentru analiza scenariilor. Ei sunt importanți pentru modulele SDG, TBWISA și pentru modelul global de predicție a seriilor de timp, deoarece influențează calitatea seriilor sintetice, estimarea relației preț-cerere și stabilitatea ferestrelor de venit. DIF-PI combină o perspectivă comportamentală la nivel de client cu o perspectivă economică la nivel de SKU.

3.4. Preprocesarea datelor

Preprocesarea transformă datele brute într-o formă standardizată, utilizabilă de toate modulele DIF-PI. Schema tranzacțională conține identificatorul clientului, identificatorul produsului, data tranzacției, cantitatea și prețul unitar. Datele sunt ordonate cronologic, iar înregistrările invalide sunt eliminate sau corectate conform regulilor de pregătire a datelor [15], [23].

Pentru modelarea comportamentului clientului, tranzacțiile sunt păstrate la nivel de eveniment de cumpărare. Această reprezentare permite calcularea intervalelor dintre achiziții și construirea exemplelor supravegheate pentru NPD. Pentru modelarea produsului, tranzacțiile sunt agregate zilnic la nivel de SKU. Cererea zilnică este calculată ca suma cantităților vândute, iar prețul zilnic este calculat ca prețul unitar ponderat cu cantitatea, atunci când acest lucru este posibil [12], [23].

Setul de date zilnice la nivel de produs este reindexat pe o grilă calendaristică completă. Zilele fără vânzări sunt păstrate ca valori explicite de cerere zero, nu eliminate. În comerțul online, absența vânzărilor poate fi un semnal real al cererii intermitente. Prețurile lipsă sunt completate astfel încât fiecare zi să aibă o referință de preț validă pentru generarea scenariilor.

Ingineria caracteristicilor include lag-uri, statistici pe ferestre mobile, indicatori calendaristici și descriptori de preț. În DIF-PI, intervenția de preț este modelată separat în etapa de scenarii, nu amestecată cu variabilele folosite pentru predicție. Această separare susține interpretarea rezultatelor: modelul de predicție învață dinamica cererii, iar TBWISA definește intervențiile și construiește scenariile de preț [10], [12], [22].

3.5. Partiționarea cronologică a datelor

Partiționarea cronologică a datelor este importantă pentru a evita folosirea informațiilor din viitor în evaluare. În problemele de serii de timp, modelul nu trebuie să utilizeze informații care nu ar fi disponibile la momentul predicției. Din acest motiv, antrenarea se face pe date istorice, iar evaluarea pe date ulterioare, pentru a păstra ordinea temporală în NPD, predicția cererii produselor, scenarii și evaluarea integrată [23], [26].

Eligibilitatea SKU-urilor este stabilită pe baza unor criterii precum lungimea istoricului, numărul de zile active, proporția zilelor fără vânzări și variația prețului. Scopul filtrării nu este eliminarea tuturor seriilor dificile, ci păstrarea unui set suficient de informativ pentru antrenare și evaluare. Seriile prea scurte sau prea rare pot produce estimări instabile, iar seriile fără variație de preț oferă suport limitat pentru analiza intervențiilor [12], [23].

Filtrarea SKU-urilor este urmată de separarea dintre setul de antrenare și setul de evaluare. Modelul global de predicție a seriilor de timp este antrenat pe un set de SKU-uri eligibile, iar studiile de caz integrate sunt realizate pe SKU-uri reținute pentru evaluare. Această separare susține validitatea evaluării, deoarece evaluarea finală nu reutilizează aceleași produse atât pentru antrenare, cât și pentru prezentarea rezultatelor principale.

CAPITOLUL 4. COMPONENTELE DE MODELARE ALE FRAMEWORK-ULUI DE INTELIGENȚĂ DECIZIONALĂ

4.1. Structura generală a framework-ului

Capitolul 4 prezintă componentele principale de modelare ale framework-ului DIF-PI și modul în care acestea transformă datele din comerțul online într-un obiect decizional. Acest obiect include o intervenție de preț recomandată, o fereastră de aplicare, un scor decizional și o etichetă de filtrare. Framework-ul este construit ca un pipeline modular de inteligență decizională, care conectează pregătirea datelor, generarea de serii de timp sintetice, predicția intenției de cumpărare, simularea scenariilor de preț, predicția cererii viitoare, optimizarea ferestrei de venit și filtrarea bazată pe explicabilitate [4], [6], [9], [12], [15].

DIF-PI pornește de la două reprezentări complementare ale datelor. Prima este tabelul tranzacțional la nivel de client, utilizat pentru modelarea comportamentului de cumpărare și pentru modulul NPD. A doua este setul de date zilnice de tip preț-cerere, utilizat pentru generarea scenariilor, predicția cererii și evaluarea veniturilor. Această separare este necesară deoarece intenția de cumpărare la nivel de client și decizia de preț la nivel de produs aparțin unor niveluri diferite de analiză [12], [15].

Structura generală este sintetizată în Figura 2, care arată legătura dintre pregătirea datelor, predicția intenției de cumpărare, generarea scenariilor, predicția cererii produselor, optimizarea ferestrei de venit și filtrarea decizională. În această arhitectură, NPD oferă un semnal temporal privind activitatea probabilă a clienților, SDG susține robustețea în regimuri cu date scurte sau incomplete, TBWISA generează scenarii de preț, iar X-TBWISA verifică stabilitatea și plauzibilitatea recomandărilor.

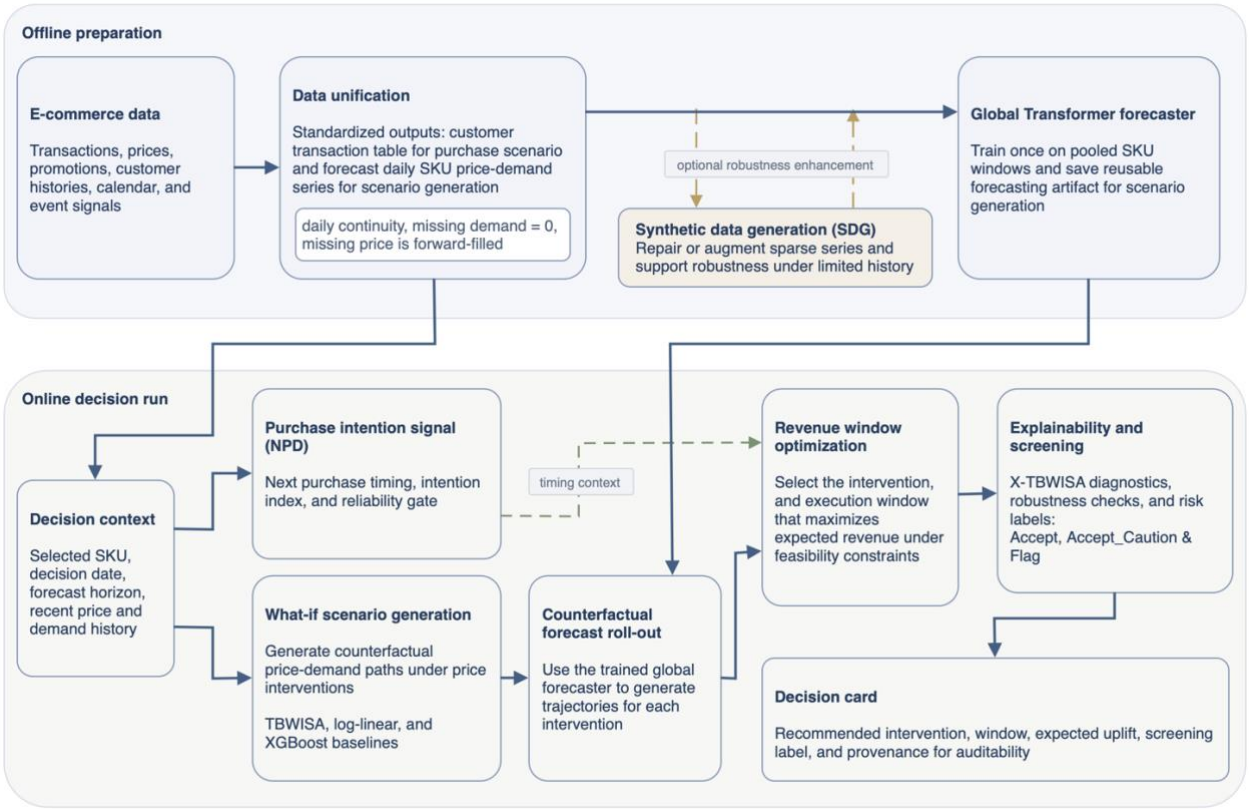

Figura 2. Arhitectura de modelare și decizie a pipeline-ului DIF-PI

4.2. Formularea framework-ului DIF-PI

DIF-PI este formulat ca o problemă de suport decizional pentru alegerea unei intervenții procentuale de preț și a unei ferestre de aplicare pentru un produs analizat. Pentru o dată selectată t_0 și un orizont de analiză H, framework-ul utilizează informațiile tranzacționale, serii de tip preț-cerere, predicția intenției de cumpărare, generarea de scenarii, determinarea cererii viitoare a produselor, optimizarea ferestrei de venit și filtrarea bazată pe explicabilitate [4], [6], [9], [12], [15], [27].

Pentru reprezentarea tranzacțională, setul de date este descris prin:

$$D^{TX} = \{(c_i, s_i, \tau_i, q_i, p_i)\}_{i=1}^{N} \tag{1}$$

unde c_i este clientul, s_i este SKU-ul, τ_i este data tranzacției, q_i este cantitatea cumpărată, iar p_i este prețul unitar. Pentru etapa de scenarii și decizie, DIF-PI folosește setul de date zilnice la nivel de SKU:

$$D_s^{SKU} = \{(t, p_{s,t}, d_{s,t})\}_{t=1}^{t_0} \tag{2}$$

unde $p_{s,t}$ este prețul zilnic, iar $d_{s,t}$ este cererea zilnică pentru SKU-ul s. Aceste două reprezentări păstrează diferența dintre analiza comportamentală la nivel de client și decizia economică la nivel de produs.

Pentru fiecare intervenție candidată $\delta \in \Delta$, DIF-PI construiește o traiectorie alternativă de preț:

$$p_{s,t}^{(\delta)} = p_{s,t}\left(1+\frac{\delta}{100}\right) \tag{3}$$

Această intervenție este folosită de TBWISA pentru a construi o traiectorie alternativă de cerere, care este estimată pe perioada analizată prin modelul global Transformer [12]. Pe baza cererii prezise și a prețului modificat conform intervenției, acesta calculează venitul estimat fiecărui scenariu.

Recomandarea finală conține intervenția de preț și fereastra de aplicare. Pentru o intervenție δ, un început de fereastră ω și o lungime ℓ, DIF-PI selectează varianta cu cel mai bun scor decizional:

$$(\delta^*, \omega^*, \ell^*) = \arg \max_{\delta \in \Delta, (\omega,\ell) \in \mathcal{C}} U_s(\delta, \omega, \ell) \tag{4}$$

unde $\mathcal{C}$ reprezintă setul ferestrelor de aplicare care respectă constrângerile definite. Rezultatul optimizării este verificat prin X-TBWISA, care atribuie o etichetă de filtrare:

$$\chi_s(\delta^*, \omega^*, \ell^*) \in \{\text{Accept, Accept Caution, Flag}\} \tag{5}$$

Obiectul decizional final produs de DIF-PI este:

$$z_s = \left(\delta^*, \omega^*, \ell^*, U_s^*, \text{uplift}_s, \chi_s, \text{audit}_s\right) \tag{6}$$

unde δ^* este intervenția de preț recomandată, ω^* începutul ferestrei, ℓ^* lungimea ferestrei, U_s^* scorul decizional, $uplift_s$ îmbunătățirea estimată, χ_s statusul de filtrare, iar $audit_s$ informațiile de trasabilitate. Această formulare arată că DIF-PI produce o recomandare care poate fi validată, nu o decizie automată.

4.3. Modulul NPD pentru predicția următoarei zile de cumpărare

Modulul NPD are rolul de a estima momentul probabil al următoarei achiziții pentru clienți. În DIF-PI, acesta nu decide prețul și nu este interpretat ca efect cauzal asupra cererii. Rolul său este de a oferi un semnal temporal despre activitatea probabilă a clienților în perioada analizată [15].

Datele de intrare ale modulului NPD sunt datele istorice tranzacționale ale clienților. Pentru fiecare client, achizițiile sunt ordonate cronologic, iar diferențele dintre două achiziții consecutive formează secvențe de intervale dintre cumpărări. Pentru fiecare client, ultimele K intervale dintre cumpărări sunt folosite ca intrare, iar următorul interval este valoarea care trebuie prezisă:

$$\mathbf{x}_{c,i} = \left[g_{c,i-K}, g_{c,i-K+1}, \dots, g_{c,i-1}\right], y_{c,i} = g_{c,i} \tag{7}$$

unde $g_{c,i}$ este intervalul dintre cumpărări pentru clientul c. Această formulare transformă predicția următoarei zile de cumpărare într-o problemă de predicție temporală bazată pe intervalele dintre achiziții.

Modelul folosit este un Transformer de tip *encoder-only*, adaptat pentru predicția seriilor de timp. Fiecare fereastră de intervale dintre cumpărări este proiectată într-un spațiu latent, îmbogățită cu informație poziționlă și procesată prin blocuri de atenție. Rezultatul este apoi proiectat către valoarea estimată a următorului interval până la cumpărare [15], [18]. În teza completă, modelul NPD produce atât o predicție a următorului interval, cât și un profil agregat al intenției de cumpărare pe orizontul decizional, iar aceste date de ieșire sunt folosite ca informații temporale de suport pentru interpretarea ferestrei de venit.

O componentă importantă este mecanismul de fiabilitate NPD. Aceasta controlează cât de mult poate influența semnalul temporal interpretarea recomandării finale:

$$\alpha = \Gamma(\mathrm{MAE}_{NPD}) \tag{8}$$

unde $\alpha \in [0,1]$ este ponderea semnalului NPD, iar $\Gamma()$ este o funcție de mapare bazată pe eroarea modelului. Dacă eroarea NPD este mică, semnalul temporal poate avea o influență mai mare. Dacă eroarea este mare, influența este redusă sau nu este utilizată. NPD contribuie în DIF-PI prin context comportamental, fără să transforme automat predicția temporală într-o decizie de preț.

4.4. Modulul SDG pentru generarea seriilor de timp sintetice

Modulul SDG este introdus pentru a susține analiza în situații în care seriile de timp sunt scurte, rare, incomplete sau sensibile din punctul de vedere al confidențialității. În comerțul electronic, astfel de situații sunt frecvente: unele produse au un istoric de vânzări scurt, unele serii sunt intermitente, iar datele la nivel de client pot avea restricții de utilizare [7], [8], [9].

În DIF-PI, datele sintetice nu înlocuiesc datele reale în evaluarea finală. Ele sunt utilizate pentru creșterea robusteții, pentru extinderea istoricului unor produse cu date puține, pentru repararea unor segmente incomplete și pentru testarea modelelor în situații cu date mai dificile. Poziționarea modulului SDG este prezentată în Figura 3, unde generarea sintetică apare ca strat de suport pentru augmentare, repararea seriilor și robustețe, nu ca substitut al datelor reale.

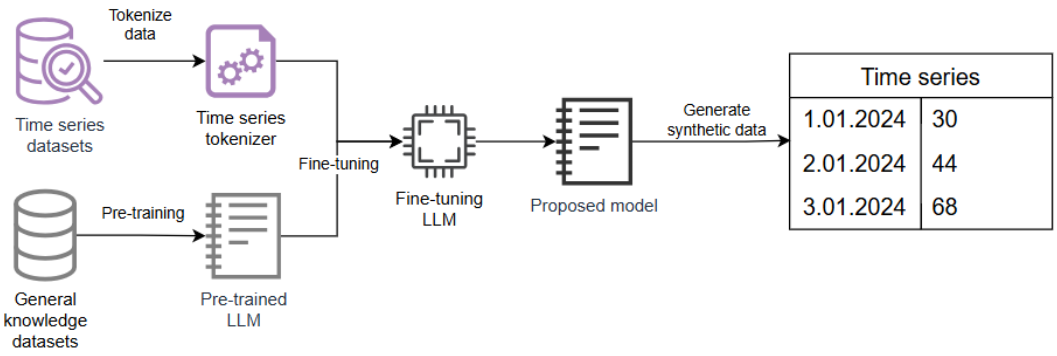

Figura 3. Poziționarea modulului SDG în DIF-PI, adaptată din [9]

Metoda SDG transformă valorile numerice ale seriilor de timp în tokeni. Pentru o fereastră de context $y_1, y_2, \ldots, y_L$, se calculează mai întâi un factor de scalare bazat pe media valorilor absolute:

$$a_y = \max\left(\varepsilon, \frac{1}{L}\sum_{i=1}^{L}|y_i|\right) \tag{9}$$

unde ε previne împărțirea la zero. Valorile seriei sunt apoi normalizate astfel:

$$\tilde{y}_i = \frac{y_i}{a_y} \tag{10}$$

După scalare, valorile sunt cuantizate într-un vocabular discret de tokeni. Această reprezentare permite folosirea unei arhitecturi de tip *encoder-decoder*, apropiată de modul în care modelele lingvistice procesează secvențe. Contextul istoric devine secvența de intrare, iar modelul generează o continuare artificială, plauzibilă, a seriei de timp [9], [20]. În implementarea DIF-PI, SDG include și mecanisme de stabilizare, precum zgomot controlat în antrenare, filtrare pe baza apropierii față de ferestre reale, calibrare sezonieră și mecanisme de rezervă pentru serii rare.

Evaluarea SDG este realizată prin trei dimensiuni: fidelitate, utilitate și confidențialitate. Fidelitatea verifică apropierea dintre distribuțiile reale și cele sintetice. Utilitatea verifică dacă seriile sintetice pot susține sarcini predictive sau de scenarii. Confidențialitatea urmărește riscul ca datele sintetice să fie prea apropiate de exemple reale.

4.5. Modulul TBWISA pentru analiza scenariilor de preț

TBWISA este componenta care transformă întrebarea de tip „ce se întâmplă dacă” într-un set de scenarii de cerere și venit. Întrebarea principală este ce s-ar putea întâmpla cu cererea și venitul dacă prețul unui produs ar fi redus sau majorat cu un anumit procent.

TBWISA combină modelarea cauzală structurală, estimarea controlată a elasticității, ajustarea neliniară a răspunsului la preț, simularea stocastică și predicția cu modelul Transformer. Această combinație permite generarea unor scenarii informate structural, dar rezultatele trebuie interpretate cu prudență [11], [12].

Pentru fiecare intervenție de preț δ, TBWISA construiește o traiectorie alternativă de preț:

$$p_t^{(\delta)} = p_t(1+p_\delta) \tag{11}$$

unde p_δ este intervenția relativă de preț. Intervenția este exprimată procentual, $p_\delta = \frac{\delta}{100}$. Pe baza acestei intervenții, TBWISA construiește o traiectorie alternativă de cerere folosind estimarea elasticității și o structură cauzală simplificată. Scopul este să se genereze scenarii coerente economic și utile pentru compararea alternativelor de preț [12].

Pentru a evita presupunerea că cererea reacționează la fel pentru toate modificările de preț, TBWISA include o ajustare neliniară a elasticității:

$$\beta^{(\delta)} = \beta\left(1+\frac{{p_\delta}^2}{2}\right) \tag{12}$$

Această relație nu este prezentată ca lege universală a cererii, ci ca o corecție pragmatică pentru intervenții mai mari. Modulul introduce perturbații stocastice controlate pentru a reflecta incertitudinea și variabilitatea din datele reale [12].

După construirea scenariilor de cerere, venitul zilnic estimat este calculat ca produs între prețul scenariului și cererea prezisă:

$$\mathrm{R}_{s,t_0+h}^{(\delta)} = p_{s,t_0+h}^{(\delta)}\,\hat{d}_{s,t_0+h}^{(\delta)} \tag{13}$$

Această formulare permite compararea scenariilor nu doar prin cerere, ci prin efectul estimat asupra venitului. Modulul TBWISA este prezentat în Figura 4. Intervențiile de preț sunt introduse în modelul structural, iar scenariile rezultate sunt propagate prin modelul Transformer. Această separare este importantă pentru interpretare: TBWISA construiește intervenția și scenariul de cerere, iar modelul de predicție estimează evoluția cererii în perioada analizată.

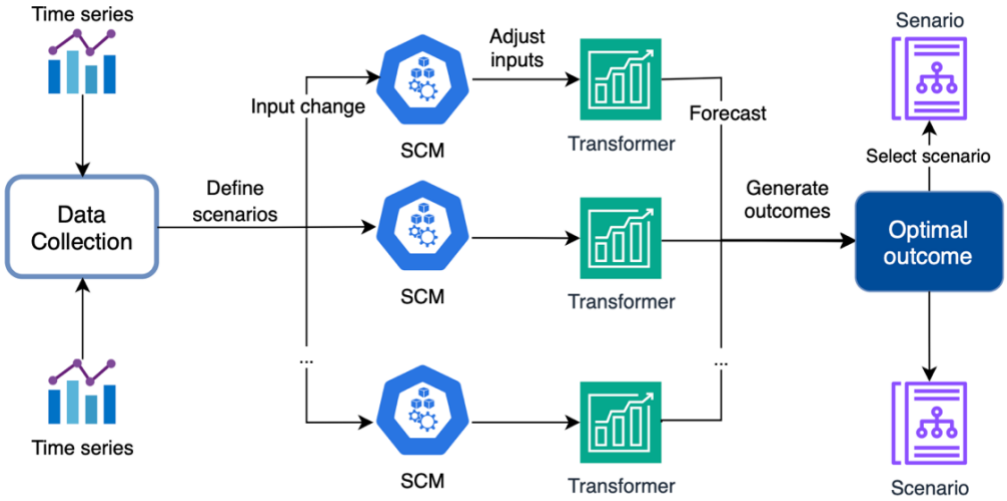

Figura 4. Arhitectura pentru generarea scenariilor TBWISA, adaptată din [12]

4.6. Modelul global Transformer pentru predicția cererii

Modelul global Transformer este utilizat pentru predicția cererii în fiecare scenariu generat. Spre deosebire de un model local, antrenat separat pentru fiecare SKU, modelul global folosește la antrenare ferestre de timp extrase din mai multe SKU-uri din setul de antrenare. Această strategie este utilă în retail, unde multe produse au istorii limitate sau cerere intermitentă [12], [18].

Pentru o serie zilnică de cerere $y_{s,t}$, o pereche intrare-ieșire pentru antrenarea supravegheată este definită astfel:

$$(x_{s,t}, y_{s,t}) = ([y_{s,t-L}, y_{s,t-L+1}, \dots, y_{s,t-1}], y_{s,t}) \tag{14}$$

Modelul învață funcția:

$$\hat{y}_{s,t} = f_\theta(x_{s,t}) \tag{15}$$

unde f_θ este modelul Transformer global, cu parametri partajați între SKU-urile de antrenare. Modelul folosește doar istoricul cererii iar efectul modificărilor de preț este introdus anterior de TBWISA în scenariile analizate.

În timpul rulării scenariilor, modelul este folosit autoregresiv. Pentru un istoric de scenariu $h_{1:T}^{(\delta)}$, predicția pe un pas este:

$$\hat{y}_{T+1}^{(\delta)} = f_\theta\left(h_{T-L+1}^{(\delta)}, \dots, h_T^{(\delta)}\right) \tag{16}$$

iar predicția seriilor de timp pe mai mulți pași este obținută recursiv:

$$\hat{y}_{T+h}^{(\delta)} = f_\theta\left(B_{h-1}^{(\delta)}[-L:]\right), \qquad h = 1, \dots, H \tag{17}$$

unde $B_{h-1}^{(\delta)}$ este buffer-ul care conține istoricul observat și predicțiile generate până la pasul anterior. Fiecare nouă predicție este adăugată în buffer, iar ultimele L observații sunt folosite ca intrare pentru următorul pas. Această procedură permite propagarea fiecărui scenariu pe întregul orizont decizional, fără a reantrena modelul pentru fiecare SKU sau intervenție.

Această separare între TBWISA și modelul global Transformer este importantă. TBWISA definește intervenția și construiește traiectoria alternativă de cerere, iar modelul Transformer estimează evoluția acesteia în perioada analizată. Modelul de predicție nu estimează direct efectul prețului, ci extinde în timp o traiectorie de cerere generată în etapa de scenarii.

4.7. Determinarea ferestrei optime de venit

După determinarea fiecărui scenariu, DIF-PI caută fereastra de aplicare care oferă cel mai bun scor decizional. Această etapă este necesară deoarece o recomandare de preț nu este completă dacă indică doar procentul de modificare. Managerul trebuie să știe când ar trebui aplicată intervenția și cât timp ar trebui menținută [12], [27].

Pentru fiecare intervenție δ, DIF-PI calculează venitul prognozat și apoi evaluează ferestre candidate. Venitul zilnic estimat este:

$$\mathrm{R}_{s,t_0+h}^{(\delta)} = p_{s,t_0+h}^{(\delta)}\, \hat{d}_{s,t_0+h}^{(\delta)} \tag{18}$$

Pentru o fereastră cu început ω și lungime l, venitul mediu pe fereastră este:

$$\bar{R}_{\omega,l}^{(\delta)} = \frac{1}{l} \sum_{h=\omega}^{\omega+l-1} R_{t_0+h}^{(\delta)} \tag{19}$$

Scorul ferestrei include venitul estimat și o penalizare pentru lungime:

$$\mathrm{score}(\omega, l) = \bar{R}_{\omega,l}^{(\delta)} - \lambda l \tag{20}$$

iar fereastra selectată este:

$$(\omega^*, l^*) = \underset{\omega,l}{\mathrm{argmax}}\, \mathrm{score}(\omega, l) \tag{21}$$

Această etapă transformă traiectoriile de cerere și venit într-o recomandare operațională. O fereastră scurtă poate fi dificil de aplicat, iar una lungă poate crește riscul sau poate reduce controlul managerial. Optimizarea nu urmărește doar cea mai mare valoare izolată, ci o recomandare fezabilă, care este apoi transmisă către modulul X-TBWISA pentru verificarea stabilității și plauzibilității.

4.8. Modulul X-TBWISA pentru explicabilitate și filtrare

X-TBWISA este stratul de explicabilitate și filtrare decizională aplicat peste rezultatele TBWISA. Rolul său este să verifice dacă recomandările generate sunt suficient de stabile, interpretabile și coerente economic pentru a putea fi analizate de manager înainte de aplicare [6].

Arhitectura X-TBWISA este prezentată în Figura 5. Partea din stânga corespunde procesului TBWISA, unde sunt generate scenariile și ferestrele candidate. Partea din dreapta adaugă modelul surogat, explicațiile TreeSHAP, verificările de stabilitate și regulile de filtrare. X-TBWISA introduce o etapă de audit între optimizarea scenariului și exportul recomandării finale.

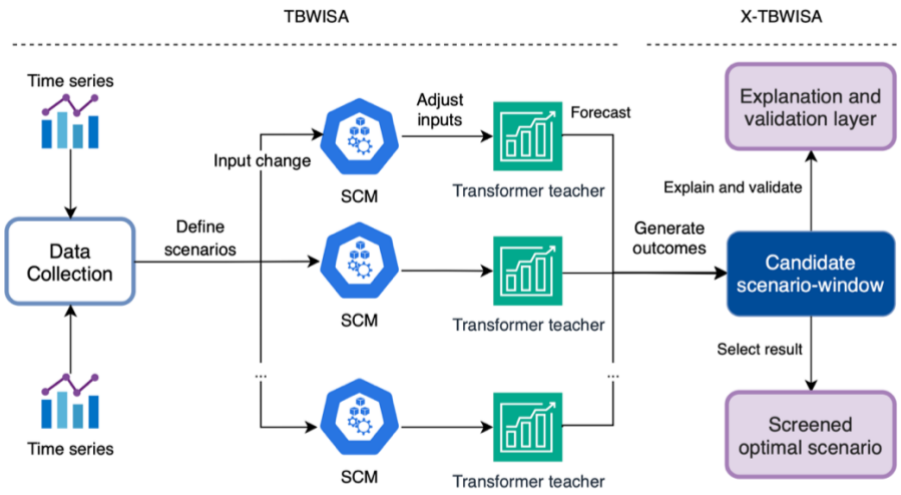

Figura 5. Arhitectura X-TBWISA, adaptată din [6]

O distincție importantă este cea dintre modelul profesor și modelul surogat. Modelul profesor este modelul global Transformer de predicție, care primește traiectoria cererii generată de scenariu și produce valorile următoare. Modelul surogat este un model XGBoost antrenat pentru a aproxima ieșirile modelului profesor. Pentru acest surogat sunt calculate explicații folosind TreeSHAP, pentru a analiza atribuțiile globale și locale ale caracteristicilor [6], [13], [14].

Pentru două intervenții vecine δ și δ', X-TBWISA măsoară stabilitatea explicațiilor prin distanța SHAP normalizată:

$$d_{\mathrm{SHAP}}(\delta, \delta') = \frac{\|\phi_\delta - \phi_{\delta'}\|_1}{\|\phi_\delta\|_1 + \varepsilon} \tag{22}$$

unde ϕ_δ este vectorul de atribuții SHAP pentru intervenția δ, iar εeste o constantă numerică mică. Pragul de drift este stabilit ca percentila 75 a distanțelor SHAP între intervenții adiacente, ceea ce oferă un prag reproductibil pentru separarea tranzițiilor stabile de cele instabile [6].

Pentru a verifica dacă drift-ul este dominat de caracteristici legate de preț, X-TBWISA calculează raportul de drift pe preț:

$$r_{\mathrm{price}}(\delta) = \frac{\sum_{j \in \mathcal{P}} |\phi_{\delta,j}|}{\sum_j |\phi_{\delta,j}| + \varepsilon} \tag{23}$$

unde $\mathcal{P} = \{delta_pct, last_price\}$ este mulțimea caracteristicilor asociate intervenției de preț. Acest raport este folosit împreună cu verificări economice simple: monotonicitate locală, coerența relației dintre preț și cerere și plauzibilitate economică. Aceste verificări nu demonstrează efecte cauzale, ci funcționează ca reguli de diagnostic pentru audit și guvernanță.

Interpretarea etichetelor de filtrare este sintetizată în Tabelul 3. X-TBWISA nu respinge automat toate scenariile imperfecte. Eticheta *Accept Caution* permite păstrarea unor alternative potențial utile, dar semnalate pentru verificare suplimentară. Această filtrare este adecvată pentru un sistem de suport decizional, deoarece rezultatul final trebuie verificat înainte de aplicare.

Tabelul 3. Etichetele de filtrare X-TBWISA și interpretarea lor

Etichetă	***Interpretare***
Accept	Scenariul este stabil și poate fi analizat ca o recomandare executabilă
Accept Caution	Scenariul este utilizabil, dar există semnale care impun prudență
Flag	Scenariul necesită revizuire umană înainte de execuție

Prin X-TBWISA, explicabilitatea este folosită pentru descrierea modelului și ca mecanism de guvernanță decizională. Scopul nu este creșterea numărului de recomandări acceptate, ci identificarea scenariilor suficient de stabile pentru a fi analizate de manager înainte de aplicare.

CAPITOLUL 5. PIPELINE-UL DIF-PI ȘI ARHITECTURA SOFTWARE

5.1. Arhitectura generală

Capitolul 5 prezintă modul în care componentele descrise anterior sunt conectate într-un framework unificat. În capitolul 4 au fost prezentate modulele principale de modelare, iar în acest capitol accentul este pus pe integrarea lor într-o arhitectură software care permite generarea recomandărilor de preț pentru cazuri concrete de decizie [27], [28].

DIF-PI este organizat ca un pipeline de inteligență decizională care pornește de la date tranzacționale și serii zilnice de tip preț-cerere și produce un obiect decizional final. Succesiunea generală poate fi sintetizată prin etapele: *predicție* → *simulare* → *prognoză* → *optimizare* → *filtrare* → *export*. Această succesiune exprimă trecerea de la analiza comportamentului și a cererii la o recomandare de preț validată prin criterii de stabilitate, plauzibilitate și explicabilitate [4], [6], [9], [12], [15].

Arhitectura este împărțită în două zone principale. Prima este zona de preprocesare și antrenare, în care datele sunt standardizate, modelele sunt antrenate, iar artefactele software sunt salvate. A doua parte este etapa de aplicare, în care modelele și artefactele salvate anterior sunt reutilizate pentru a analiza un SKU, o dată de decizie, un orizont de predicție și mai multe intervenții posibile de preț. Această separare este importantă deoarece DIF-PI nu reantrenează toate modelele pentru fiecare recomandare. Modelele pot fi antrenate periodic, iar rularea decizională poate fi executată atunci când este necesară evaluarea unei intervenții de preț [28].

Pipeline-ul este ilustrat în Figura 6 și arată cum datele procesate, modulele antrenate și mecanismele de generare a scenariilor sunt conectate pentru a determina recomandarea finală [28]. DIF-PI nu trebuie interpretat ca o simplă succesiune de modele predictive. Fiecare etapă are un rol diferit: datele sunt folosite pentru predicția comportamentului de cumpărare, apoi sunt generate scenarii de preț, cererea este estimată pentru fiecare scenariu, se selectează fereastra de venit, iar recomandarea este filtrată înainte de export. Astfel, framework-ul păstrează distincția dintre predicție, simulare, prognoză, optimizare și filtrare decizională.



Figura 6. Pipeline-ul DIF-PI de la predicție la recomandarea de preț

5.2. Integrarea modulelor în framework-ul DIF-PI

În DIF-PI, fiecare modul produce un rezultat cu rol precis pentru etapa următoare. Modulul NPD produce un semnal temporal al intenției de cumpărare [15]. Modulul SDG oferă suport pentru situații cu serii de timp scurte, rare sau incomplete [9]. TBWISA produce scenarii contrafactuale de preț și cerere [12]. Modelul global Transformer estimează evoluția acestor scenarii în perioada analizată, iar optimizarea selectează fereastra de venit. Modulul X-TBWISA adaugă eticheta de filtrare decizională [6].

Această integrare permite ca rezultatul final să conțină mai multă informație decât o predicție izolată. Obiectul decizional include intervenția procentuală de preț, începutul ferestrei de aplicare, lungimea ferestrei, scorul decizional, uplift-ul estimat, statusul de filtrare și informațiile de audit. Recomandarea poate fi astfel analizată de manager sau de persoana responsabilă de decizie, nu executată automat fără verificare [27].

Un aspect important al integrării este folosirea unor reprezentări standardizate. Tabelul tranzacțional este utilizat pentru modulul NPD, iar setul de date pentru SDG, TBWISA, modelul global de predicție și evaluarea integrată. Această separare reduce ambiguitatea dintre analiza la nivel de client și decizia la nivel de produs [12], [15].

5.3. Reproductibilitatea și structura implementării software

Reproductibilitatea este susținută printr-o implementare organizată în notebook-uri, module reutilizabile, modele salvate și fișiere exportate. Această structură separă etapele de pregătire a datelor, antrenare, validare și aplicare a DIF-PI [28].

Etapa de preprocesare standardizează datele de retail și exportă cele două reprezentări: tabelul tranzacțional și setul de date zilnice la nivel de SKU. Etapa NPD construiește secvențele de intervale dintre cumpărări, antrenează modelele de predicție a următoarei zile de cumpărare și exportă rezultatele de validare. Etapa SDG antrenează generatorul de serii de timp sintetice și îl compară cu modele de referință. Etapa de predicție salvează modelul global Transformer împreună cu configurația și separarea SKU-urilor în seturi de antrenare și evaluare [9], [12], [15], [28].

Modulele TBWISA și X-TBWISA sunt folosite pentru generarea scenariilor și pentru filtrarea decizională [6], [12]. În etapa finală, DIF-PI combină modelele și rezultatele salvate anterior pentru a genera recomandări pentru SKU-urile analizate în studiile de caz. Pipeline-ul include încărcarea datelor procesate, selectarea SKU-ului analizat, calcularea contextului NPD, încărcarea modelului global de predicție, generarea scenariilor, calcularea veniturilor, optimizarea ferestrei, aplicarea X-TBWISA și exportul rezultatelor [27], [28].

Un avantaj al acestei structuri este trasabilitatea. Dacă o recomandare este analizată ulterior, se poate verifica ce date au fost folosite, ce model a generat predicția, ce grilă de intervenții a fost evaluată, ce scenariu a fost selectat și ce etichetă de filtrare a fost atribuită. Acest lucru este util într-un sistem de suport decizional, unde rezultatul trebuie să poată fi explicat și revizuit [4], [6].

Salvarea modelelor, configurațiilor și rezultatelor intermediare reduce riscul unor modificări necontrolate între rulări. Această organizare face rezultatele mai ușor de reprodus și permite aplicarea aceleiași analize pentru alte produse sau alte perioade [28].

5.4. Protocolul studiilor de caz și aplicații practice

În studiile de caz, framework-ul este utilizat după aceeași logică de rulare. Fiecare analiză pornește de la un SKU selectat, o dată de decizie, un orizont de predicție și o grilă discretă de intervenții de preț. Aceeași procedură este aplicată pentru toate cazurile, astfel încât rezultatele să fie comparabile și ușor de validat [27].

Protocolul începe cu descrierea contextului de bază: comportamentul recent al cererii, istoricul prețului și regimul seriei. Apoi sunt evaluate mai multe intervenții procentuale de preț. Pentru fiecare intervenție, TBWISA construiește un scenariu de cerere, modelul global Transformer determină evoluția cererii în perioada analizată, iar etapa de optimizare caută fereastra de venit cu cel mai bun scor [10], [12], [18].

După selecția ferestrei, X-TBWISA aplică filtrarea decizională. Această etapă este necesară deoarece o recomandare cu scor ridicat nu este automat suficientă pentru aplicare managerială. Dacă scenariul are explicații instabile, dacă apar semnale că nu este plauzibil economic sau dacă modelul surogat nu aproximează suficient de bine modelul profesor, rezultatul poate fi marcat cu prudență sau cu Flag [6].

Rezultatele finale sunt exportate în forme potrivite pentru analiză: tabele cu scenariile candidate, tabele cu ferestrele selectate, diagnostice SHAP, grafice pentru studiul de caz și un sumar JSON al recomandării finale. Aceste exporturi permit refacerea figurilor și tabelelor din evaluare și susțin utilizarea framework-ului într-un proces de analiză managerială [4], [6], [28].

Utilizarea practică a DIF-PI trebuie înțeleasă ca suport decizional, nu ca automatizare completă a deciziei de preț. Framework-ul poate recomanda o intervenție, o fereastră și o etichetă de filtrare, dar decizia finală rămâne la manager sau la persoana responsabilă de decizie. Recomandarea trebuie analizată împreună cu datele de context, constrângerile comerciale, stocul, campaniile active, marjele și alte informații care nu sunt modelate explicit în DIF-PI.

CAPITOLUL 6. EVALUARE

6.1. Metodologia experimentală

Capitolul 6 prezintă evaluarea framework-ului DIF-PI și verifică dacă modulele propuse pot susține un pipeline coerent de inteligență decizională pentru comerț online. Evaluarea urmărește acuratețea predictivă și utilitatea decizională a rezultatelor. Evaluarea utilizează metrici de predicție a seriilor de timp, diagnostice de plauzibilitate economică, analiză de stabilitate, filtrare prin explicabilitate și evaluare integrată pe studii de caz [4], [6], [27].

Metodologia este organizată pe trei niveluri. Primul nivel validează componentele individuale: NPD, SDG, TBWISA și X-TBWISA. Al doilea nivel evaluează DIF-PI pe trei SKU-uri, alese pentru a acoperi regimuri diferite de cerere: cerere regulată, cerere intermitentă și sensibilitate ridicată la preț. Al treilea nivel folosește analiza de ablație pentru a examina contribuția componentelor și sensibilitatea recomandării finale la eliminarea sau înlocuirea unor mecanisme interne.

Evaluarea respectă ordinea temporală a datelor, modelele sunt antrenate pe perioade anterioare și evaluate pe perioade ulterioare. Se evită astfel folosirea informațiilor din viitor în procesul de testare. Pentru modelele de predicție a seriilor de timp, este utilizat un protocol de tip *rolling-origin*, în care prognoza este repetată din mai multe puncte temporale, iar rezultatele sunt agregate [23], [26].

Pentru scenariile de preț, evaluarea are o limitare naturală deoarece nu pot fi observate simultan toate traiectoriile alternative care ar fi rezultat din intervenții diferite de preț. Dacă în date a fost observat un anumit preț, nu există în același timp și observația reală pentru toate celelalte intervenții posibile. Validarea TBWISA se bazează pe mai multe criterii de evaluare: acuratețea prognozei pentru evoluția observată a cererii, coerența elasticității, plauzibilitatea economică, sensibilitatea la zgomot și stabilitatea ferestrelor de venit [11], [12].

Metricile sunt adaptate rolului fiecărui modul. Pentru NPD, sunt utilizate MAE și RMSE exprimate în zile, deoarece obiectivul este estimarea intervalului până la următoarea cumpărare. Pentru SDG, evaluarea folosește fidelitatea, utilitatea predictivă și confidențialitatea. Pentru TBWISA, sunt evaluate acuratețea predicției, robustețea față de zgomotul în estimarea elasticității, consistența monotonică, plauzibilitatea economică și stabilitatea ferestrelor. Pentru X-TBWISA, sunt analizate fidelitatea modelului surogat, diagnosticele TreeSHAP, distanța dintre explicații pentru intervenții apropiate și distribuția statusurilor de filtrare [6], [9], [12], [15].

6.2. Validarea modulului NPD

Validarea modulului NPD verifică dacă predicția următoarei zile de cumpărare poate oferi un semnal temporal util pentru DIF-PI. Modulul este evaluat ca model comportamental, nu ca mecanism direct de stabilire a prețului. Rolul său este să indice perioadele în care activitatea de cumpărare este mai probabilă și să ofere context pentru interpretarea ferestrelor de venit [15].

Rezultatele agregate ale benchmark-ului NPD sunt sintetizate în Tabelul 4, unde modelele sunt comparate prin MAE și RMSE. Modelul Transformer obține cea mai mică eroare medie dintre modelele comparate, iar varianta clustered Transformer are rezultate apropiate. Modelele de referință, precum XGBoost, LSTM și ARIMA, obțin erori mai mari în această evaluare.

Tabelul 4. Benchmark agregat pentru predicția NPD pe modelele comparate

Model	***MAE mediu***	***RMSE mediu***
Transformer	8.291	11.545
Transformer clustered	8.465	11.888
XGBoost	11.621	15.748
LSTM	13.883	17.745
ARIMA	14.791	18.390

Rezultatele agregate trebuie interpretate împreună cu analiza pe segmente comportamentale. Deși Tabelul 4 arată un MAE mediu de 8,291 zile pentru Transformer la nivel agregat, în segmentul clienților cu activitate ridicată eroarea este mai mică, de aproximativ 3,2 zile MAE. Acest lucru indică faptul că predicția următoarei cumpărări este mai stabilă atunci când istoricul clientului conține suficiente achiziții. Pentru clienții cu activitate redusă, erorile cresc, deoarece istoricul conține mai puține observații și intervale mai lungi între cumpărări.

Această diferență justifică introducerea mecanismului de fiabilitate NPD în DIF-PI. Semnalul NPD este util atunci când predicția temporală este suficient de stabilă, dar nu trebuie folosit cu aceeași pondere pentru toți clienții sau toate regimurile comportamentale. În DIF-PI, NPD contribuie ca semnal temporal, iar influența lui este controlată în funcție de calitatea validării.

6.3. Validarea modulului SDG

Validarea urmărește să determine dacă seriile de timp sintetice generate pot susține sarcini de retail fără a înlocui datele reale. Evaluarea este realizată pe trei dimensiuni: *fidelitate*, *utilitate* și *confidențialitate*. În practică, optimizarea implică un compromis între cele trei dimensiuni. Această abordare este necesară deoarece un generator poate produce date realiste ca distribuție, dar mai puțin utile pentru sarcini predictive sau mai riscante din perspectiva protecției datelor [7], [8], [9].

Sinteza comparativă a modulelor de generare sintetică este prezentată în Figura 7, unde modelele sunt evaluate prin scoruri agregate de fidelitate, utilitate și confidențialitate. Rezultatele arată că SDG obține performanțe bune la fidelitate și utilitate. În comparațiile de fidelitate, modelul propus are o distanță Wasserstein mai mică decât unele modele de referință și se poziționează favorabil în raport cu metodele comparate. În comparația agregată, SDG obține un scor de fidelitate 85 și un scor de utilitate 75, depășind celelalte metode pe aceste dimensiuni.

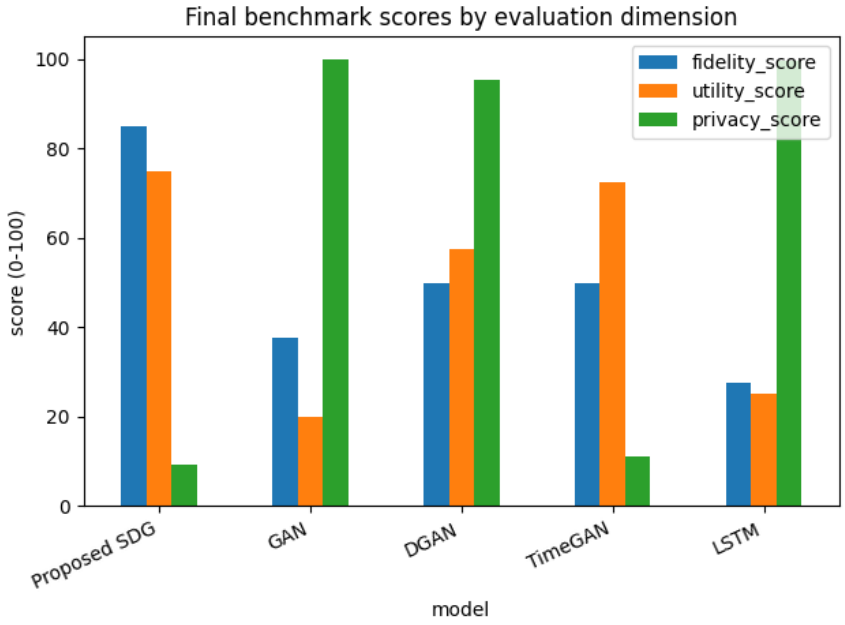

Figura 7. Comparația modelelor SDG pe dimensiunile fidelitate, utilitate și confidențialitate

Acest rezultat trebuie interpretat împreună cu evaluarea confidențialității. Deși SDG obține rezultate bune la fidelitate și utilitate, scorul de confidențialitate arată că seriile sintetice pot păstra asemănări cu datele reale. Din acest motiv, modulul nu trebuie prezentat ca o soluție care elimină complet riscurile de confidențialitate. În DIF-PI, SDG este utilizat pentru a sprijini analiza în cazul seriilor scurte, rare sau incomplete, pentru testarea robusteții și pentru completarea unor istorii insuficiente. Datele sintetice completează datele reale, dar nu le înlocuiesc în evaluarea finală.

6.4. Validarea modulului TBWISA

Validarea TBWISA verifică dacă motorul de scenarii poate genera traiectorii de cerere și venit mai stabile și mai plauzibile economic decât modelele de referință. TBWISA este comparat cu abordări mai simple, precum LogLinear și XGBoost, folosind acuratețea predicției, robustețea la zgomotul elasticității, consistența economică și stabilitatea ferestrelor de venit [11], [12].

Acuratețea generatoarelor de scenarii este comparată în Figura 8, unde TBWISA este analizat în raport cu modelele LogLinear și XGBoost. Rezultatele comparației sunt prezentate în Tabelul 5, care include MAE și RMSE pentru modelele analizate. TBWISA obține erori mai mici decât modelele de referință în experimentul efectuat. Acest rezultat nu validează direct toate scenariile generate, dar susține faptul că mecanismul TBWISA este mai bine aliniat cu evoluția observată a cererii decât alternativele testate.

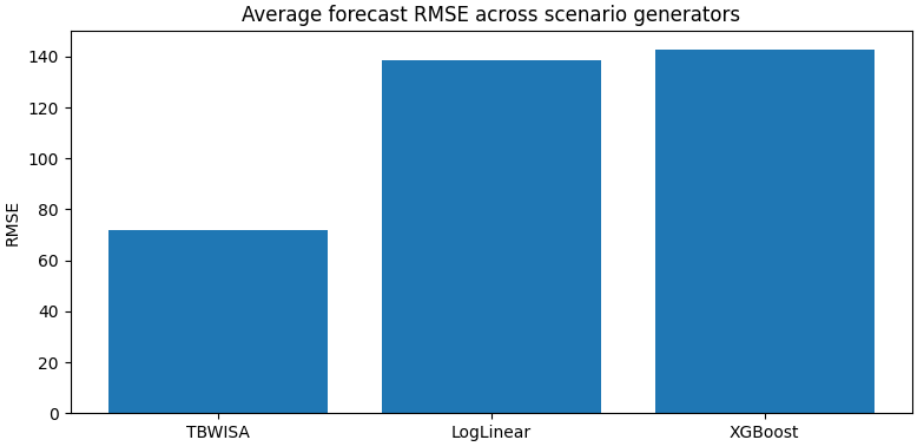

Figura 8. Acuratețea predicției pentru generatoarele de scenarii

Tabelul 5. Comparația acurateței pentru generatoarele de scenarii

Model	***MAE mediu***	***RMSE mediu***	***Interpretare***
TBWISA	68.276	71.788	cea mai bună concordanță cu evoluția observabilă a cererii
LogLinear	128.013	138.688	model de referință structural simplu
XGBoost	131.293	142.847	model ML de referință cu stabilitate economică mai slabă

Diagnosticele de plauzibilitate economică sunt sintetizate în Tabelul 6, care compară TBWISA cu modelele LogLinear și XGBoost. TBWISA are o rată de consistență monotonică de 0,923 și o rată de plauzibilitate economică de 1, în timp ce XGBoost are valori mai reduse pentru aceste criterii. Un sistem de scenarii pentru preț nu trebuie doar să prezică valori apropiate de observații, ci să păstreze și o logică economică rezonabilă. În DIF-PI, relația negativă dintre preț și cerere este folosită ca regulă de plauzibilitate, nu ca dovadă cauzală complet identificată [10], [11], [12].

Tabelul 6. Diagnostice de plauzibilitate pentru TBWISA și modelele de referință

Model	***Rată consistență monotonică***	***Rată plauzibilitate economică***	***Corelație medie preț-cerere***	***Elasticitate implicită medie***	***Dispersia elasticității***
TBWISA	0.923	1	-0.863	-1.158	1.202
LogLinear	0.9	0.9	-0.794	-1.161	0.94
XGBoost	0.669	0.583	-0.131	-0.844	8.308

În analiza stabilității ferestrelor se urmărește dacă generatoarele de scenarii conduc la ferestre de aplicare consistente, atunci când sunt evaluate mai multe intervenții de preț. Rezultatele sunt sintetizate în Tabelul 7, în care σ reprezintă deviația standard, iar Δ preț mediu reprezintă modificarea medie de preț recomandată. Toate modelele păstrează același început și aceeași lungime a ferestrei în această comparație, însă diferența apare la stabilitatea scorului ferestrei. TBWISA are cea mai mică deviație standard a scorului ferestrei, comparativ cu LogLinear și XGBoost. Această diferență indică faptul că TBWISA produce recomandări mai coerente la nivelul scorului decizional, chiar dacă poziția și lungimea ferestrei rămân stabile pentru toate modelele. TBWISA este mai potrivit ca generator de scenarii în contextul evaluării realizate deoarece combină acuratețea, plauzibilitatea economică și stabilitatea ferestrei recomandate.

Tabelul 7. Stabilitatea ferestrei optime pentru generatoarele de scenarii

Model	***σ început fereastră***	***σ lungime fereastră***	***σ scor fereastră***	***Δ preț mediu***	***Interpretare***
TBWISA	0.0	0.0	0.402	-0.25	moment și durată stabile, cea mai redusă variație a scorului
LogLinear	0.0	0.0	0.467	-1.5	moment și durată stabile, variație redusă a scorului
XGBoost	0.0	0.0	2.475	1.667	moment și durată stabile, dar variație mai mare a scorului

6.5. Validarea modulului X-TBWISA

Validarea X-TBWISA verifică dacă stratul de explicabilitate și filtrare decizională poate oferi diagnostice utile pentru scenariile generate de TBWISA. X-TBWISA este evaluat pe același set de SKU-uri din setul de evaluare, folosind scenariile generate de TBWISA și prognozele produse de modelul global Transformer. Scopul este să se determine dacă modelul surogat este suficient de fidel, dacă explicațiile sunt stabile între intervenții apropiate și dacă etichetele *Accept*, *Accept Caution* și *Flag* sunt utile pentru diferențierea recomandărilor [6].

Fidelitatea surogatului este evaluată prin MAE și RMSE pe niveluri de intervenție. Rezultatele arată că surogatul este în general suficient de precis pentru analiză, dar nu uniform pe întreaga grilă de intervenții. Cele mai mici erori apar pentru intervențiile +5%, -5% și +10%, iar erori mai mari apar în jurul intervențiilor 0%, -15% și +15%. Această variație este importantă deoarece explicațiile sunt mai credibile în zonele în care surogatul aproximează mai bine modelul profesor.

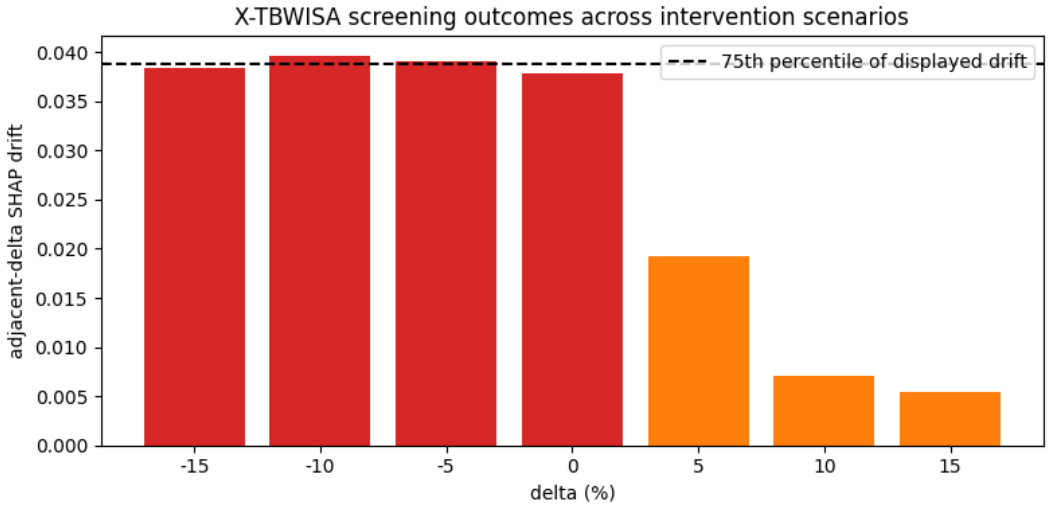

Figura 9. Rezultatele filtrării X-TBWISA pe scenarii de intervenție

Rezultatele filtrării X-TBWISA pe scenarii de intervenție sunt prezentate în Figura 9. Figura arată cum se modifică drift-ul explicațiilor SHAP între intervenții apropiate și evidențiază zonele în care scenariile sunt marcate cu *Flag* sau *Accept Caution*. X-TBWISA are un comportament conservator. Scopul acestuia nu este să accepte cât mai multe scenarii, ci să identifice situațiile în care recomandarea este stabilă și suficient de bine susținută de explicații. Intervențiile negative și zona de bază prezintă drift-ul explicațiilor SHAP mai ridicat, în timp ce unele intervenții pozitive au drift mai redus, dar rămân marcate cu prudență din cauza verificărilor economice.

Distribuția agregată a statusurilor de filtrare este prezentată în Tabelul 8. Tabelul arată cât de frecvent X-TBWISA acceptă direct o recomandare, o marchează cu prudență sau o trimite spre revizuire. *Flag* este cea mai frecventă etichetă de filtrare, urmat de *Accept Caution*, iar eticheta *Accept* apare mai rar. Această distribuție trebuie interpretată astfel: un procent ridicat de *Flag* nu indică o eroare a framework-ului, ci arată că X-TBWISA funcționează ca strat conservator de guvernanță și marchează multe scenarii pentru verificare umană.

Tabelul 8. Distribuția statusurilor de filtrare X-TBWISA pentru scenariile decizionale

Etichetă de filtrare	***Nr. scenarii decizionale***	***Pondere scenarii decizionale***	***Interpretare***
Flag	216	0.514	necesită revizuire înainte de recomandare
Accept Caution	165	0.392	utilizabil, dar necesită verificare suplimentară
Accept	39	0.092	stabil și analizabil ca recomandare

6.6. Evaluarea integrată a framework-ului DIF-PI

Evaluarea integrată verifică dacă modulele DIF-PI pot funcționa împreună într-un pipeline de suport decizional. Această secțiune urmărește recomandarea generată pentru trei SKU-uri reprezentative: un caz cu cerere regulată, un caz cu cerere intermitentă și un caz sensibil la preț [6], [12], [27]. Cele trei cazuri sunt folosite pentru a ilustra comportamentul DIF-PI în regimuri diferite.

Sinteza rezultatelor evaluării integrate este prezentată în Tabelul 9. Tabelul compară intervenția recomandată, poziția ferestrei, lungimea ferestrei, uplift-ul estimat și statusul de filtrare pentru cele trei regimuri de cerere analizate. DIF-PI nu produce aceeași recomandare pentru toate regimurile. Pentru cazul cu cerere regulată și pentru cazul sensibil la preț, recomandarea este o reducere de preț, dar intensitatea efectului este diferită. Cazul cu cerere regulată are un uplift estimat modest, în timp ce cazul sensibil la preț are un uplift estimat mai mare. Pentru cazul intermitent, recomandarea se schimbă în direcția unei majorări de preț, dar primește statusul *Accept Caution*, ceea ce indică o recomandare utilizabilă, dar mai fragilă.

Tabelul 9. Recomandări integrate DIF-PI pentru cele trei SKU-uri analizate

SKU	***Regim***	***Intervenția de preț***	***Început fereastră***	***Lungime fereastră***	***Uplift estimat***	***Etichetă de filtrare***
1070820	cerere regulată	-15%	22	8	0.038	*Accept*
9553031	cerere intermitentă	+15%	19	8	0.122	*Accept Caution*
908531	sensibil la preț	-15%	21	9	0.433	*Accept*

Această evaluare arată că DIF-PI adaptează atât direcția intervenției, cât și nivelul de încredere la regimul empiric al produsului. Framework-ul nu urmărește aplicarea unor reguli uniforme de preț. Acesta urmărește construirea unei recomandări analizabile, însoțită de informații privind uplift-ul, fereastra de aplicare și statusul de filtrare.

6.7. Analiza de ablație

Analiza de ablație verifică modul în care rezultatul final se modifică atunci când anumite componente sunt eliminate sau înlocuite. Această secțiune arată dacă DIF-PI funcționează ca un ansamblu de module cu roluri distincte sau doar ca o combinație de componente independente [29].

În analiză sunt incluse mai multe variante reduse ale framework-ului: înlocuirea modelului global de predicție, simplificarea estimării elasticității, eliminarea simulării stocastice, eliminarea suportului SDG, eliminarea ponderii temporale NPD și eliminarea filtrării X-TBWISA. Rezultatele principale sunt sintetizate în Tabelul 10, care compară aceste variante cu configurația DIF-PI.

Tabelul 10. Rezumatul ablațiilor DIF-PI pentru SKU-urile de studiu de caz

Ablație	***Modificare scor fereastră***	***Modificare uplift***	***Deplasare început fereastră***	***Deplasare lungime fereastră***	***Rată Accept / Accept Caution***
Eliminare elasticitate neliniară	0.170	0.007	0.334	-0.334	1
Eliminare clustering	0	0	0	0	1
Varianta completă DIF-PI	0	0	0	0	1
Eliminare pondere temporală NPD	0	0	0	0	1
Eliminare SDG	0	0	0	0	1
Eliminare X-TBWISA	0	0	0	0	0
Elasticitate controlată înlocuită cu log-log	-0.042	-0.025	-2.333	0.333	1
Eliminare simulare stocastică	0.518	0.013	-0.333	0	1
Înlocuire model de predicție cu ARIMA	-2.524	0.005	-1.333	-1	1

Înlocuirea modelului global de predicție cu ARIMA produce cea mai mare scădere a scorului mediu al ferestrei. Simplificarea elasticității și eliminarea simulării stocastice afectează, de asemenea, scorul și poziția ferestrei. Eliminarea SDG, a clustering-ului sau a ponderii temporale NPD nu modifică recomandarea în cele trei cazuri analizate. Această observație nu înseamnă că modulele respective sunt inutile, ci că, pentru SKU-urile selectate și pentru perioada analizată, recomandarea a rămas stabilă. Pentru alte serii, cu cerere intermitentă, istorice mai scurte sau evoluții mai greu de prognozat, aceste componente pot avea un rol mai vizibil. Eliminarea X-TBWISA nu afectează scorul numeric, dar elimină statusul de filtrare. Rezultatul confirmă rolul său de guvernanță și validare a deciziilor. X-TBWISA nu este introdus pentru a crește scorul decizional, ci pentru a separa recomandările stabile de cele instabile.

6.8. Discuții, limitări și semnificație managerială

Rezultatele din Capitolul 6 arată că DIF-PI utilizează datele de retail pentru a genera recomandări de preț structurate și interpretabile. NPD estimează momentul următoarei achiziții, SDG ajută în situații cu date istorice scurte sau incomplete, TBWISA generează scenarii de preț coerente economic, iar X-TBWISA filtrează recomandările pe baza stabilității. Evaluarea integrată arată că aceste componente pot funcționa împreună într-un pipeline care poate fi verificat.

Rezultatele trebuie interpretate în limitele metodologiei. Datele sunt observaționale, iar intervențiile de preț nu sunt randomizate. Scenariile TBWISA sunt simulări informate structural, nu efecte cauzale complet identificate. Evaluarea integrată folosește trei SKU-uri reprezentative, ceea ce este potrivit pentru demonstrarea funcționării framework-ului, dar nu suficient pentru o generalizare completă la toate categoriile de produse.

O altă limitare este legată de datele comerciale disponibile. Costurile, marjele, stocurile, acțiunile concurenților, strategia de brand și constrângerile operaționale nu sunt modelate complet. Din acest motiv, recomandările trebuie interpretate ca suport decizional. Managerul sau persoana responsabilă de decizie trebuie să verifice recomandarea în raport cu obiectivele comerciale și contextul operațional.

Semnificația managerială a rezultatelor constă în forma obiectului decizional generat. DIF-PI nu produce doar o valoare, ci un pachet care include intervenția de preț, fereastra de aplicare, uplift-ul estimat, scorul decizional, statusul de filtrare și informațiile de audit. Acest tip de rezultat este mai potrivit pentru analiza managerială decât o prognoză izolată, deoarece poate fi comparat și revizuit.

Interpretarea managerială a modulelor este sintetizată în Tabelul 11. Fiecare modul are un rol tehnic și o interpretare managerială. Această separare este importantă deoarece DIF-PI nu trebuie interpretat ca un singur model predictiv, ci ca un framework de suport decizional care combină predicția, simularea, prognoza, optimizarea și filtrarea recomandărilor.

Tabelul 11. Interpretarea managerială a modulelor DIF-PI

Modul	***Rol tehnic***	***Interpretare managerială***
NPD	estimare temporală la nivel de client	indică perioade cu activitate probabilă mai ridicată
SDG	augmentare și suport pentru robustețe	ajută în cazul seriilor scurte, rare sau afectate de constrângeri de utilizare
TBWISA	scenarii structurale de preț	simulează reduceri/majorări înainte de execuție
X-TBWISA	filtrare bazată pe explicabilitate	susține verificarea și controlul riscului
DIF-PI	recomandare optimizată și filtrată	oferă fereastra, intervenția de preț, uplift-ul și statusul de filtrare

CAPITOLUL 7. CONCLUZII

7.1. Sinteza rezultatelor obținute

Teza urmărește proiectarea, implementarea și evaluarea unui framework de inteligență decizională pentru predicția intenției de cumpărare a consumatorilor în comerțul online și pentru susținerea deciziilor de ajustare a prețului. Cercetarea urmărește construirea unui pipeline care conectează datele tranzacționale, predicția comportamentală, generarea de scenarii, predicția cererii viitoare, optimizarea ferestrei de venit și filtrarea bazată pe explicabilitate.

Rezultatele arată că intenția de cumpărare poate fi analizată pe două niveluri complementare. La nivelul clienților, aceasta este legată de istoricul tranzacțiilor, intervalele dintre cumpărări, recență, frecvență și regularitate. La nivelul produselor, ea este reflectată prin cererea zilnică, răspunsul la modificările de preț și venitul estimat în scenarii alternative. Această separare permite framework-ului DIF-PI să conecteze analiza comportamentului clienților cu evaluarea deciziilor de preț.

Validarea modulelor evidențiază rolul distinct al componentelor propuse. NPD estimează momentul probabil al următoarei achiziții, SDG susține analiza atunci când datele sunt scurte, rare sau incomplete, TBWISA generează scenarii de preț coerente economic, iar X-TBWISA filtrează recomandările pe baza stabilității, explicabilității și plauzibilității economice. Evaluarea integrată arată că valoarea framework-ului propus rezultă din combinarea acestor componente într-un sistem decizional coerent, nu din utilizarea izolată a unui singur model.

Evaluarea unui sistem de inteligență decizională trebuie să includă acuratețea predicțiilor, plauzibilitatea economică, stabilitatea și interpretarea recomandării. O recomandare de preț trebuie să fie plauzibilă economic, stabilă, interpretabilă și suficient de bine susținută pentru a fi analizată înainte de aplicare. DIF-PI produce un obiect decizional care include intervenția de preț, fereastra de aplicare, uplift-ul estimat, scorul decizional și eticheta de filtrare. Studiile de caz arată că recomandarea se adaptează la regimul SKU-ului analizat, fie că este vorba despre cerere regulată, cerere intermitentă sau sensibilitate ridicată la preț. Framework-ul propus nu aplică aceeași regulă tuturor produselor, ci construiește recomandări adaptate datelor disponibile.

7.2. Contribuțiile principale ale tezei

Contribuția principală a tezei este definirea framework-ului DIF-PI pentru inteligență decizională în comerțul online. Acesta integrează predicția intenției de cumpărare, generarea de serii de timp sintetice, analiza scenariilor de preț, predicția cererii, optimizarea ferestrei de venit și filtrarea prin explicabilitate. Deciziile de preț necesită nu doar estimarea valorilor viitoare, ci și evaluarea alternativelor, interpretarea riscului și verificarea stabilității recomandării.

La nivel metodologic, teza integrează patru componente principale. Modulul NPD este utilizat pentru predicția următoarei zile de cumpărare, iar SDG este adaptat pentru generarea de serii de timp sintetice în contexte de retail cu serii de timp istorice scurte, rare, incomplete sau sensibile din punctul de vedere al confidențialității. TBWISA este definit ca generator de scenarii de preț, combinând modelarea cauzală structurală, estimarea controlată a elasticității, simularea stocastică, predicția cu Transformer și optimizarea ferestrei de venit. X-TBWISA completează această logică printr-un strat de explicabilitate și filtrare decizională bazat pe model surogat și explicații TreeSHAP.

La nivel experimental, contribuția constă în evaluarea framework-ului pe trei niveluri: validarea modulelor, evaluarea integrată și analiza de ablație. Această evaluare arată cum contribuie fiecare componentă la calitatea recomandării finale, la stabilitatea ferestrei de venit și la interpretarea rezultatului.

7.3. Limitări și considerații privind validitatea

Rezultatele trebuie interpretate în limitele datelor disponibile și ale ipotezelor metodologice utilizate. Datele analizate sunt observaționale, iar intervențiile de preț nu sunt randomizate. Scenariile generate prin TBWISA sunt interpretate ca simulări informate structural, nu ca efecte cauzale complet identificate. Relația dintre preț și cerere este modelată astfel încât să respecte o logică economică plauzibilă, dar modelul nu poate explica toate sursele reale ale variației cererii.

O altă limitare este legată de simplificarea structurii cauzale și a obiectivului de optimizare. Framework-ul modelează relația principală dintre preț și cerere, însă nu include explicit toți factorii relevanți, precum stocurile, marjele, costurile, campaniile externe, strategiile concurenților sau interacțiunile dintre produse. Limitările apar și în componentele de suport. SDG poate ajuta în regimuri cu date insuficiente, dar nu elimină complet compromisul dintre fidelitate, utilitate și confidențialitate. X-TBWISA oferă explicații și etichete de filtrare utile pentru audit, însă acestea descriu comportamentul modelului surogat, nu întregul sistem comercial real.

Evaluarea integrată este realizată pe trei SKU-uri reprezentative. Aceste cazuri arată cum se comportă DIF-PI în regimuri diferite de cerere și verifică dacă modulele funcționează coerent într-un sistem de suport decizional. Rezultatele trebuie interpretate ca suport pentru analiză, nu ca decizii automate. Decizia finală rămâne la manager sau la persoana responsabilă de decizie, care poate lua în considerare și informații care nu sunt incluse explicit în model, precum stocuri, marje, campanii active sau obiective operaționale.

7.4. Direcții viitoare de cercetare

Direcțiile viitoare urmăresc consolidarea componentei cauzale și extinderea validării. Framework-ul ar putea fi îmbunătățit prin experimente controlate, teste A/B sau metode avansate de inferență cauzală, pentru a evalua mai precis efectul modificărilor de preț asupra cererii și venitului. Evaluarea ar trebui extinsă la mai multe SKU-uri, categorii, perioade și contexte comerciale.

O altă direcție privește extinderea obiectivelor de optimizare. În forma actuală, framework-ul este centrat pe venit și pe scorul decizional asociat ferestrei de aplicare. În aplicații practice, decizia de preț depinde și de marje, profit, stocuri, costuri logistice, costuri de campanie, constrângeri operaționale și efecte între produse.

Dezvoltări suplimentare sunt necesare și pentru modulele SDG și X-TBWISA. Pentru SDG, o direcție importantă este echilibrarea mai bună între fidelitate, utilitate și confidențialitate. Pentru X-TBWISA, cercetările viitoare pot include praguri adaptive, explicații temporale mai detaliate, comparații între mai multe tipuri de modele surogat și monitorizarea drift-ului explicațiilor după aplicarea recomandărilor.

BIBLIOGRAFIE

[1] S. Chen, Z. Xu, D. Xu, and X. Gou, "Customer purchase prediction in B2C e-business: A systematic review and future research agenda," *Expert Syst. Appl.*, vol. 252, p. 124261, 2024, doi: 10.1016/j.eswa.2024.124261.

[2] C. Wissuchek and P. Zschech, "Prescriptive Analytics Systems Revised: A Systematic Literature Review from an Information Systems Perspective," *Information Systems and e-Business Management*, vol. 23, no. 2, pp. 279–353, 2025, doi: 10.1007/s10257-024-00688-w.

[3] D. Cirqueira, M. Hofer, D. Nedbal, M. Helfert, and M. Bezbradica, "Customer Purchase Behavior Prediction in E-commerce: A Conceptual Framework and Research Agenda," in *New Frontiers in Mining Complex Patterns*, Springer, 2020, pp. 119–136. doi: 10.1007/978-3-030-48861-1_8.

[4] L. Y. Pratt and N. E. Malcolm, *The Decision Intelligence Handbook: Practical Steps for Evidence-Based Decisions in a Complex World*. O'Reilly Media, 2023.

[5] L. Pratt, C. Bisson, and T. Warin, "Bringing Advanced Technology to Strategic Decision-Making: The Decision Intelligence/Data Science (DI/DS) Integration Framework," *Futures*, vol. 152, p. 103217, 2023, doi: 10.1016/j.futures.2023.103217.

[6] A. Grigoraș and F. Leon, "X-TBWISA: Explainable What-If Scenario Generation Using Transformers and SHAP Guidance," *Buletinul Institutului Politehnic din Iași (The Bulletin of the Polytechnic Institute of Iași), accepted for publication*, 2026.

[7] R. Shi, Y. Wang, M. Du, X. Shen, and X. Wang, "A Comprehensive Survey of Synthetic Tabular Data Generation," 2025. doi: 10.48550/arXiv.2504.16506.

[8] G. C. N. Kindji, L. M. Rojas-Barahona, E. Fromont, and T. Urvoy, "Tabular Data Generation Models: An In-Depth Survey and Performance Benchmarks with Extensive Tuning," *Neurocomputing*, vol. 658, p. 131655, 2025, doi: 10.1016/j.neucom.2025.131655.

[9] A. Grigoraș and F. Leon, "Synthetic Time Series Generation for Decision Intelligence Using Large Language Models," *Mathematics*, vol. 12, no. 16, p. 2494, 2024, doi: 10.3390/math12162494.

[10] T. T. Nagle, J. E. Hogan, and J. Zale, *The Strategy and Tactics of Pricing: A Guide to Growing More Profitably*, 5th ed. Routledge, 2016.

[11] J. Pearl, *Causality: Models, Reasoning, and Inference*, 2nd ed. Cambridge University Press, 2009.

[12] A. Grigoraș and F. Leon, "Generating and Optimizing What-If Scenarios Using a Transformers-Based Forecasting Model," in *Proceedings of the 29th International Conference on System Theory, Control and Computing (ICSTCC 2025)*, Cluj-Napoca, Romania, 2025, pp. 529–534. doi: 10.1109/ICSTCC66753.2025.11240464.

[13] S. M. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions," in *Advances in Neural Information Processing Systems 30*, 2017, pp. 4768–4777.

[14] S. M. Lundberg *et al.*, "From Local Explanations to Global Understanding with Explainable AI for Trees," *Nat. Mach. Intell.*, vol. 2, no. 1, pp. 56–67, 2020, doi: 10.1038/s42256-019-0138-9.

[15] A. Grigoraș and F. Leon, "Transformer-Based Model for Predicting Customers' Next Purchase Day in e-Commerce," *Computation*, vol. 11, no. 11, p. 210, 2023, doi: 10.3390/computation11110210.

[16] P. S. Fader and B. G. S. Hardie, “Probability Models for Customer-Base Analysis,” *Journal of Interactive Marketing*, vol. 23, no. 1, pp. 61–69, 2009, doi: 10.1016/j.intmar.2008.11.003.

[17] T. Reutterer, M. Platzer, and N. Schröder, “Leveraging purchase regularity for predicting customer behavior the easy way,” *International Journal of Research in Marketing*, vol. 38, no. 1, pp. 194–215, 2021, doi: 10.1016/j.ijresmar.2020.09.002.

[18] Q. Wen *et al.*, “Transformers in Time Series: A Survey,” in *Proceedings of the Thirty-Second International Joint Conference on Artificial Intelligence*, 2023, pp. 6778–6786. doi: 10.24963/ijcai.2023/759.

[19] A. Vaswani *et al.*, “Attention Is All You Need,” in *Advances in Neural Information Processing Systems*, 2017.

[20] A. F. Ansari *et al.*, “Chronos: Learning the Language of Time Series,” *Transactions on Machine Learning Research*, 2024, [Online]. Available: https://openreview.net/forum?id=gerNCVqqtR

[21] S. Gathani, Z. Liu, P. J. Haas, and Ç. Demiralp, “What-If Analysis for Business Professionals: Current Practices and Future Opportunities,” in *Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems*, 2025. doi: 10.1145/3706598.3713672.

[22] G. J. Tellis, “The Price Elasticity of Selective Demand: A Meta-Analysis of Econometric Models of Sales Response,” *Journal of Marketing Research*, vol. 25, no. 4, pp. 331–341, 1988, doi: 10.1177/002224378802500401.

[23] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. OTexts, 2021.

[24] J.-T. Wei, “A Review of the Application of the RFM Model,” *African Journal of Business Management*, vol. 6, no. 12, pp. 4552–4565, 2012.

[25] A. Handojo, “A Multi-layer Recency Frequency Monetary Method for Customer Segmentation,” *Cogent Business & Management*, vol. 10, no. 1, 2023.

[26] C. Bergmeir and J. M. Benítez, “On the Use of Cross-Validation for Time Series Predictor Evaluation,” *Inf. Sci. (N. Y).*, vol. 191, pp. 192–213, 2012, doi: 10.1016/j.ins.2011.12.028.

[27] D. Bertsimas and N. Kallus, “From Predictive to Prescriptive Analytics,” *Manage. Sci.*, vol. 66, no. 3, pp. 1025–1044, 2020, doi: 10.1287/mnsc.2018.3253.

[28] M. Schlegel and K.-U. Sattler, “Capturing end-to-end provenance for machine learning pipelines,” *Inf. Syst.*, vol. 132, p. 102495, 2025, doi: 10.1016/j.is.2024.102495.

[29] R. Meyes, M. Lu, C. W. de Puiseau, and T. Meisen, “Ablation Studies in Artificial Neural Networks,” 2019, doi: 10.48550/arXiv.1901.08644.

LISTA LUCRĂRILOR PUBLICATE

Lista include lucrările asociate direct contribuțiilor prezentate în teză, conform capitolului de contribuții și bibliografiei tezei:

- A. Grigoraș and F. Leon, “Transformer-Based Model for Predicting Customers’ Next Purchase Day in e-Commerce,” Computation, vol. 11, no. 11, art. 210, 2023, doi: 10.3390/computation11110210 , IF 2.2, Q2, cited by 19;
- A. Grigoraș and F. Leon, “Synthetic Time Series Generation for Decision Intelligence Using Large Language Models,” Mathematics, vol. 12, no. 16, art. 2494, 2024, doi: 10.3390/math12162494 , IF 2.592, Q1, cited by 8;
- A. Grigoraș and F. Leon, “Generating and Optimizing What-If Scenarios Using a Transformers-Based Forecasting Model,” in Proceedings of the 29th International Conference on System Theory, Control and Computing (ICSTCC 2025), Cluj-Napoca, Romania, Oct. 2025, pp. 529–534, doi: 10.1109/ICSTCC66753.2025.11240464;
- A. Grigoraș and F. Leon, “X-TBWISA: Explainable What-If Scenario Generation Using Transformers and SHAP Guidance,” Buletinul Institutului Politehnic din Iași, acceptat pentru publicare;
- A. Grigoraș and F. Leon, “Scenario Generation Using Transformers for Retail Data,” oral communication, 8th International Conference of the Doctoral School, Iași, Romania, May 14–16, 2025.