

Lucrare prezentată la
cel de-al IX-lea Congres
al profesiei
de auditor financiar
din România

Previziunea veniturilor din buget cu ajutorul modelului seriilor de timp ARIMA

*Drd. Ionela URSU,
Universitatea „Alexandru Ioan Cuza” din Iași,
Facultatea de Economie și Administrarea Afacerilor,
e-mail: ionela.ursu92@gmail.com*

Rezumat

În ultimele decenii informația a devenit una din cele mai importante resurse ale unei companii orientate spre profit, iar managementul întreprinderii moderne, bazat pe flexibilitate și dinamism, impune o informare complexă și operativă. Dar cum se pot obține informații relevante, pertinente și în timp util? Ce metode, instrumente se pot folosi pentru a oferi cele mai corecte informații atunci când vorbim de planificarea și previziune? Un instrument de bază al contabilității și controlului de gestiune este reprezentat de buget, remarcându-se în special funcția de previziune a acestuia. În acest context, pentru acest studiu s-a avut în vedere previziunea veniturilor din buget cu ajutorul seriilor de timp de tip ARIMA. S-a observat o tendință crescătoare a previziunii pentru anul analizat, semn favorabil pentru companie în ceea ce privește creșterea veniturilor.

Cuvinte cheie: buget; previziune; modele de previziune; serii de timp; ARIMA; SPSS;

Clasificarea JEL: M41

Vă rugăm să citați acest articol astfel:

Ursu, I. (2026), Forecasting Budget Revenues Using the ARIMA Time Series Model, *Audit Financiar*, vol. XXIV, no. 1(181)/2026, pp.186-202, DOI: 10.20869/AUDITF/2026/181/005

Link permanent pentru acest document:

<http://dx.doi.org/10.20869/AUDITF/2026/181/005>

Data primirii articolului: 16.07.2025

Data revizuirii: 4.08.2025

Data acceptării: 13.01.2026

1. Introducere

Din punct de vedere istoric, bugetele au jucat întotdeauna un rol important în administrarea afacerilor (*Libby, Lindsay, 2010*). Bugetul de afaceri s-a dezvoltat în principal în perioada 1895-1920 ca urmare a dezvoltării industriale, standardizării producției și concurenței de pe piață. Bugetele sunt utilizate în întreaga lume și deservesc mai multe scopuri: planificare, evaluarea performanței, motivarea angajaților, alocarea resurselor companiei, controlul și implementarea strategiilor.

Este instrumentul fundamental de planificare pe termen scurt (de obicei 1 an), orientat spre o gestiune previzională profitabilă. Obiectivele din buget trebuie să corespundă strategiei definite la nivelul entității traduse prin plan (*Caraiani C., 2010, p. 37*).

Previziunea reprezintă baza de pornire a bugetării. Astfel, a bugeta înseamnă a prevedea și a decide, iar a previziona înseamnă a cunoaște înainte de a acționa (*Badea F., Dobrin C., 2006, p. 71 și 81*).

În prezent folosirea previziunilor nu se realizează doar pentru predicții asupra aspectelor economice, politice, sociale dar și pentru *decizii de business în timp real*. Previziunea este un angajament față de viitor, dar și o atitudine științifică. Previziunile au la bază metode științifice, statistice, economice sau de altă natură, deci previziunea se sprijină pe cunoaștere (*Badea F., Dobrin C., 2006, p. 82*).

Pe baza structurii sistemului bugetar putem distinge două tipuri de bugete: determinante (reprezintă temelia bugetului) și rezultante (sunt induse de bugetele determinante). Bugetele determinante sunt reprezentate de bugetul de vânzări și bugetul de producție. Bugetele rezultante sunt reprezentate de bugetul de aprovizionare, cheltuieli administrative, investiții, trezorerie ș.a. (*Budugan D., 2001, p. 52*).

Având în vedere că punctul de plecare în elaborarea bugetelor îl reprezintă previziunea veniturilor ne propunem să realizăm un **model de predicție** a vânzărilor cu ajutorul **seriilor cronologice**, care vor reprezenta apoi baza de construcție a celorlalte bugete, mai concret se va utiliza modelul seriilor de timp ARIMA.

Datele utilizate sunt preluate de la o companie care are drept obiect de activitate producția. Din motive de confidențialitate nu putem divulga numele companiei, datele prelucrate sunt reale și au fost extrapolate din sistemul ERP SAP. Pentru acest studiu se vor utiliza datele istorice

din bugete privind unitățile fizice fabricate în perioada 2019-2023, iar predicția se va realiza pentru anul 2024.

Lucrarea include trei secțiuni, după cum urmează: prima secțiune vizează analiza literaturii cu accent pe noțiuni privind modelele de previziune. Urmează prezentarea metodologiei de cercetare, variabilele utilizate, modelele ARIMA propuse și rezultatele predicției modelului, iar ultima parte vizează concluziile studiului.

2. Analiza literaturii de specialitate

Sistemul de bugete reprezintă un mod de gestiune previzională pe termen scurt care cuprinde planificarea și controlul bugetar. Obiectivul sistemelor de bugete este reprezentat de obținerea de informații în scopul planificării evenimentelor din cadrul unei entități (*Caraiani C., et. al., 2010, p. 42*). Practic, totalitatea bugetelor individuale coordonate între ele este denumită sistem bugetar (*Horvath et. al., 2009, p. 145*).

Bugetul reprezintă un instrument de planificare, iar obiectivele bugetare trebuie să corespundă strategiei entității tradusă prin plan (*Caraiani C., et. al., 2010, p.37*). Bugetul exprimă viziunea conducerii asupra așteptărilor privind activitatea firmei pentru o perioadă de timp. Procesul de realizare precum și execuția bugetului presupun acțiuni complexe deoarece o multitudine de variabile, factori pot afecta și influența atingerea sau nu a obiectivelor propuse (*Rachlin R., 2007, p. 3*).

Bugetarea mai reprezintă în viziunea autorilor (*Horvath et. al., 2009, p. 140*) un sistem de planificare al rezultatului și care determină o derulare clară a planurilor de acțiune. Bugetul este o previziune cifrică a obiectivelor, care trebuie să corespundă strategiei entității (*Caraiani C., 2010, p. 37*). Bugetul prezice rezultatul anticipat al unei strategii de afaceri (*Dimitris C.N., 2006, p. 237*).

Dacă bugetarea reprezintă înscrierea în bugete a datelor rezultate în urma previziunilor (*Budugan D., 2001, p. 43*), următoarele întrebări care se pot pune sunt: Ce informații înscriem în bugete? Cum obținem aceste informații? Previziunea reprezintă baza de pornire a bugetării. Astfel, a bugeta înseamnă a prevedea și a decide, iar a previziona înseamnă a cunoaște înainte de a acționa (*Badea F., Dobrin C., 2006, p. 71 și 81*).

În prezent folosirea previziunilor nu se realizează doar pentru predicții asupra aspectelor economice, politice, sociale dar și pentru *decizii de business în timp real*.

Previțiunea este un angajament față de viitor dar și o atitudine științifică. Previțiunile au la bază metode științifice, statistice, economice sau de altă natură, deci previțiunea se sprijină pe cunoaștere. Pentru a previționa avem nevoie de informații care fac referire la situația prezentă și trecută a întreprinderii, astfel că informațiile devin materia primă de decizie a managementului (Badea F., Dobrin C., 2006, p. 82).

Previțiunea sau predicția provine din limba franceză "prevision", care înseamnă a anticipa evoluția și apariția evenimentelor, pe baza datelor cunoscute din trecut (dar și din prezent); precum și studiul legilor obiective în context temporal și spațial (Guță A.J., Catrina I., 2020).

Cum se obțin previțiunile? Cu ajutorul **modelelor de previțiune**. Modelele de previțiune reprezintă „inima” unei predicții. Pentru a obține cele mai bune rezultate avem nevoie de date corecte dar și de modelul potrivit. Cu cât datele și modelul sunt mai compatibile, cu atât mai precisă va fi previțiunea unui fenomen. În opinia autorilor Jain L. D. C, Malehorn J. (2006, p. 46) există trei principale tipuri de modele:

- a) **Modelul Seriilor de Timp:** acest model funcționează pe baza extrapolării datelor din trecut și se pleacă de la presupunerea că același trend va continua și în viitor. Exemple de astfel de modele pot fi *exponential smoothing* (netezire exponențială) și ARIMA (Zhao L., Mbachu J., Zhang H., 2019);
- b) **Modelul Cauză-Efect:** se bazează pe existența unei cauze (numită *driver* sau variabilă independentă) și a unui efect (numit variabilă dependentă). De exemplu, dacă vânzările depind de totalul cheltuielilor cu publicitatea pentru un produs, atunci vânzările reprezintă variabila dependentă iar publicitatea variabila independentă, driver-ul, cauza. Cu ajutorul acestui model putem determina relația dintre variabile și să le proiectăm în viitor. Un alt exemplu pornește de la următoarea relație între cheltuieli (y) și activități (x): $y=F(x)$, unde, cheltuielile prevăzute Y s-au stabilit plecând de la nivelul activității ce poate fi prevăzut (Badea F., Dobrin C., 2006, p. 72). Acest model se folosește atunci când există o strânsă legătură între variabile și nu se va schimba semnificativ în viitor sau cel puțin în perioada de previționare;
- c) **Modelul Critic.** Acest model se folosește în mod deosebit atunci când nu avem date anterioare pentru analiză. În acest caz ne vom folosi de proceduri specifice pentru a realiza o previțiune cum ar fi:

modelul Analog, Delphi, Diffusion, PERT (performance evaluation review technique), Survey. Le vom descrie pe scurt în continuare.

- Analog – în cadrul acestui model se caută o variabilă similară pentru a fi folosită drept bază pentru previțiune. De exemplu, când televizoarele au apărut prima dată pe piață analiștii estimau vânzările pe baza vânzărilor produselor radio. Această tehnică se folosește pentru produsele noi pe piață, unde nu avem o evidență trecută;
- Delphi - în acest caz previționarea se realizează cu ajutorul unui grup de expertiză din domeniul respectiv;
- Diffusion - analiștii previționează datele pe baza ciclului de viață al produsului;
- PERT – prin această abordare analistul previționează cu ajutorul unui expert în domeniu care îi va furniza trei estimări (pesimistă, optimistă, cel mai probabil) care vor servi drept bază pentru prognoză;
- Survey - datele primare provin din chestionare, aplicate prin mail, telefon sau față în față, care reprezintă baza de pornire pentru previționare în anumite cazuri specifice.

Într-un context informațional se mai impune o anumită clarificare: care este diferența dintre date și informații? Informația reprezintă un mesaj, aduce un spor de cunoaștere și reduce incertitudinea, iar datele reprezintă simboluri pentru o informație potențială, dar necesită o prelucrare a lor pentru a deveni informații utile. Astfel, datele devin materia primă pentru obținerea informațiilor (Nica P., Iftimescu A., 2008, p. 363).

La baza unei previțiuni stau datele pe care le avem la dispoziție. În funcție de datele pe care le avem la dispoziție putem selecta și modelul corect. La pregătirea datelor trebuie să avem în vedere următoarele aspecte (Jain L.D.C., Malehorn J., 2006, p. 52):

- consistența datelor: ne asigurăm ca avem date pentru toată perioada analizată;
- apariția valorilor extreme (outliers): prin outlier înțelegem valori extreme, neobișnuite, ieșite din comun. Acestea sunt apariții random, care nu fac parte din model, astfel că acestea fie se ajustează, fie se alege un model care ține evidența unei astfel de apariții, de exemplu,

- folosirea unei *variabile dummy* în cadrul regresilor care ajustează outlier-ul;
- structura datelor: acestea se pot schimba odată cu apariția unor noi produse, fuziuni de întreprinderi, pătrunderea pe o nouă piață etc.; în astfel de cazuri comparația cu datele din trecut nu mai este posibilă;
 - date lipsă: dacă ne lipsesc date dintr-o anumită perioadă (de exemplu o lună, 1 an) trebuie să inserăm valorile lipsă (prin estimări); dacă vrem, de exemplu, să aplicăm modelul seriilor de timp am putea întâmpina probleme;
 - sezonalitate: face referire la fluctuații care au loc în mod periodic. De exemplu, vânzările unui magazin cu anumite produse specifice pot fi foarte ridicate în luna decembrie, când are loc Crăciunul, sau anumite echipamente sportive pot fi vândute mai mult iarna decât vara și invers. Dacă observăm un astfel de trend vom ține cont de el pe parcursul previzionării;
 - existența unei relații cauză-efect între date: dacă vânzările noastre sunt direct afectate de practicarea unor campanii publicitare atunci modelul cauză-efect este mai potrivit de folosit pentru că Seriiile de Timp nu vor surprinde o asemenea relație între date;
 - erori în procesul de previziune: acestea sunt cel mai greu de măsurat. Putem calcula erorile, după caz, folosind una din formulele (Jain L.D.C., Malehorn J., 2006, p. 60):
 - a. Eroare de previziune (%) = $(\text{Actual-Previzionat})/\text{Actual} \times 100$ - ne arată cât de mult previziunea deviază de datele actuale;
 - b. Eroare de previziune (%) = $(\text{Previzionat-Actual})/\text{Previzionat} \times 100$ - ne arată cât de mult datele realizate deviază de ce am previzionat.

Metodologia aplicată depinde de obiectul de activitate al întreprinderii. De exemplu, pentru produse precum cimentul, petrolul, electricitatea previziunea se poate face pe fiecare produs în parte. Pentru produsele de larg consum previziunea se realizează în termeni de capacitate de producție sau desfacere. Pot apărea restricții la nivel de previziuni, de exemplu, restricții generate de piața unde firma își va vinde produsele, apariția concurenței etc., de aceea recurgem la metode care să ne reducă din această incertitudine (Badea F., Dobrin C., 2006, p. 126).

3. Metodologia cercetării. Modelul seriilor de timp ARIMA

Între funcțiile bugetului se remarcă funcția de previziune (pe lângă cea de control și echilibru financiar), care reprezintă o estimare financiară a resurselor și cheltuielilor pentru activitățile întreprinderii (Budugan D., 2001, p. 46). Având în vedere că punctul de plecare în elaborarea bugetelor îl reprezintă previziunea veniturilor ne propunem în continuare să realizăm un model de predicție a vânzărilor cu ajutorul seriilor cronologice, care vor reprezenta apoi baza de construcție a celorlalte bugete. Datele seriilor cronologice sunt ordonate conform **variabilei timp** (Cărbunaru B., Băcescu C., 2013). Expresia generală a unei serii cronologice este de forma (Anghelache C., Manole A., 2012):

$$Y_i = f(t_i), \text{ unde}$$

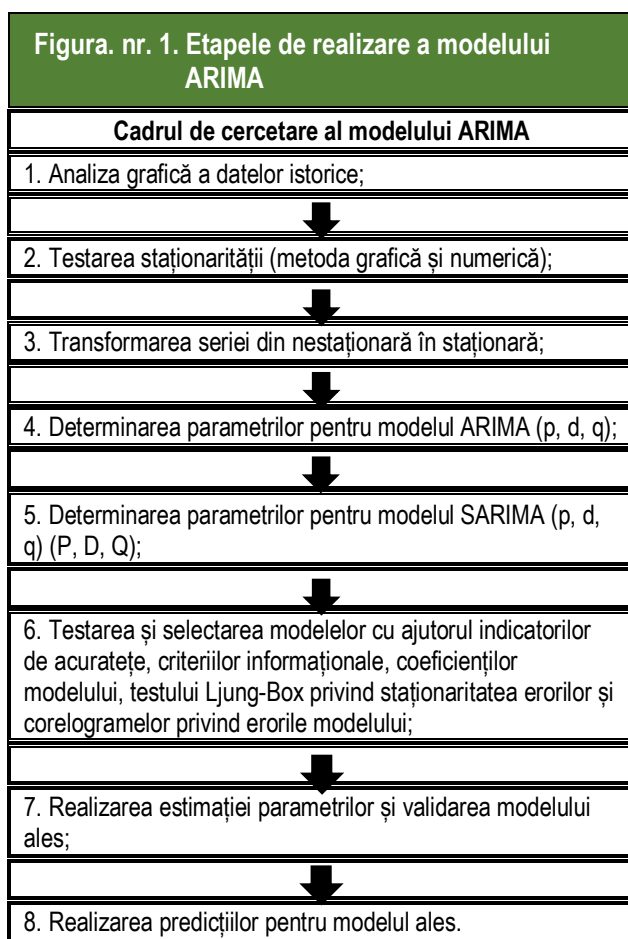
Y_i = valorile variabilei studiate

t_i = valorile numerice ale variabilei timp

De multe ori se preferă **înlocuirea variabilelor independente** efective, care acționează asupra vânzărilor (cum ar fi: nivelul veniturilor consumatorilor, nivelul inflației, structura populației, prețul produselor, bugetul publicității etc.) cu **variabila timp**; aceasta din cauza lipsei informațiilor cu privire la variabilele cauzale, pe de o parte, dar și din cauza costurilor mari pentru a obține asemenea informații (Zamfir M., 2017, p. 65).

Planificarea bugetelor începe mereu cu bugetul de vânzări, care indică cantitatea fizică de unități care urmează să fie produse și vândute într-o anumită perioadă (Chorafas Dimitris 2006, p. 237). Acest buget reprezintă apoi baza pentru bugetele costurilor de producție, urmând să fie luat în considerare pentru cantitățile de materii prime și materiale necesare pe unitate de produs, de unde va rezulta bugetul costurilor pentru materiale. Ținând cont de aceste informații se continuă apoi cu realizarea bugetului de achiziții. Se planifică apoi și bugetul cheltuielilor cu salarii directe și indirecte, precum și bugetul cheltuielilor generale de administrație. Bugetul de investiții ține cont de bugetul producției în vederea achiziției sau modernizării utilajelor. Trecerea bugetării de la calcul numeric la unul bazat pe numerar reprezintă bugetarea fluxului de trezorerie, precum și elaborarea unui bilanț planificat și a contului de rezultate previzionate (Horvath et. al., 2009, p. 154).

Previziunea vânzărilor se poate realiza: pe termen scurt (pentru elaborarea programelor de producție, incluzând previziunea stocurilor de produse finite sau programele de aprovizionare cu materii prime și materiale etc.) și pe termen lung și mediu (pentru elaborarea programelor de investiții și a planurilor de finanțare), (Badea F., Dobrin C., 2006, p. 121). Autorii Ikenna A., et. al.(2017) susțin faptul că estimarea, previziunea vânzărilor reprezintă fundamentul, punctul de plecare în vederea construcției bugetelor.



Sursa: prelucrare proprie

Previziunea veniturilor din buget s-a realizat pentru acest studiu cu ajutorul seriilor cronologice, mai concret modelul seriilor de timp ARIMA. Redăm în **Figura nr. 1** etapele de realizare a acestui proces urmând ca apoi acestea să fie prezentate în detaliu.

Primul concept de clarificat atunci când vorbim de serii de timp ARIMA (Auto-Regressive Integrated Moving Average) este dacă o serie este staționară sau nu.

Determinarea acestui concept este importantă deoarece staționaritatea unei serii poate influența puternic comportamentul și proprietățile acesteia (Brooks C., 2008, p. 233). O serie care este staționară se caracterizează prin faptul că media, varianța și covarianța nu depind de timp, sunt constante. O serie nestaționară, în schimb, nu respectă una din condițiile enumerate anterior, adică valoarea variabilei depinde de valoarea anterioară. Dacă o serie este nestaționară poate apărea fenomenul de corelație artificială între variabile, adică deși valoarea coeficientului este mare nu există concret o legătură între acestea. Mai poate apărea și fenomenul de regresie falsă, adică există o legătură logică, modelul este semnificativ însă nu avem o legătură logică între variabile (Jemna D., 2009, p. 209-210).

În practică bineînțeles că este foarte greu să găsim serii staționare, motiv pentru care vom recurge la procedee de transformare a seriei. Pentru testarea staționarității se pot folosi metode grafice (pe baza coeficienților de autocorelație) și numerice (pe bază de teste). Pentru realizarea acestora am folosit programul de statistică SPSS v30, iar datele utilizate sunt reprezentate de datele istorice din bugetul de venituri (în volume fizice).

Redăm în primul rând seria de date în **Figura nr. 2**, unde deja la o primă analiză ne dăm seama că avem o serie staționară deoarece observăm o tendință crescătoare și nu una constantă.


Înainte de a proceda la testarea cu ajutorul celor două modele dorim să precizăm câteva concepte de care ne vom folosi în cele ce urmează. Primul este *funcția de autocorelație*, care măsoară intensitatea legăturii dintre variabile și ia valoarea între -1 și +1. *Funcția de autocorelație parțială* măsoară intensitatea legăturii dintre variabile, dar controlând și influența variabilelor pentru un decalaj k. *Decalajul* (sau *lag*) reprezintă un operator care realizează corespondența dintre valoarea seriei la un moment t și unul anterior. Operatorul *diferență* se utilizează la transformarea unei serii nestaționare în serie staționară și realizează corespondența dintre valoarea seriei la momentul t și diferența dintre valoarea seriei la momentul t și valoarea seriei la un moment de timp anterior (Jemna D., 2009, p. 211).

Utilizând *metoda grafică* pentru a testa staționaritatea, ne vom folosi de *corelograma coeficienților de autocorelație*. Dacă valorile funcției de autocorelație se păstrează în limitele intervalului de încredere, înseamnă că seria este staționară. În schimb, dacă valorile descresc exponențial, înseamnă că seria este nestaționară (Jemna D., 2009, p. 212).

Putem observa ușor din corelograma reprezentată în **Figura nr. 3** faptul că seria este *nestaționară*, deoarece


valorile descresc și depășesc limitele intervalului până la un decalaj (lag) egal cu 12.

Figura nr. 2. Seria de date



Sursa: prelucrare proprie în SPSS

Figura nr. 3. Corelograma seriei nestaționare



Sursa: prelucrare proprie în SPSS

Metoda numerică se realizează cu ajutorul testului Ljung-Box (Tabelul nr. 1), plecând de la formularea ipotezelor (Jemna D., 2009, p. 213):

H0: $\rho_k = 0$, toți coeficienții sunt simultan zero – seria este staționară

H1: ρ_k toți coeficienții nu sunt simultan zero – seria *nu* este staționară

Rezultă $Sig = < 0,001 < 0,05$, adică pentru fiecare decalaj (lag) semnificația testului este $< 0,001 \rightarrow$ se respinge ipoteza H0 și se acceptă ipoteza H1, adică **seria este nestaționară**.

Tabelul nr. 1. Metoda numerică de testare

Autocorrelations						
Series: Unități fizice						
Lag	Autocorrelation	Std. Error ^a	Value	Box-Ljung Statistic	df	Sig. ^b
1	,626	,126	24,712	1	1	<,001
2	,659	,125	52,588	2	2	<,001
3	,630	,124	78,464	3	3	<,001
4	,546	,123	98,247	4	4	<,001
5	,563	,122	119,716	5	5	<,001
6	,517	,120	138,115	6	6	<,001
7	,431	,119	151,183	7	7	<,001
8	,445	,118	165,366	8	8	<,001
9	,360	,117	174,826	9	9	<,001
10	,306	,116	181,801	10	10	<,001
11	,292	,115	188,288	11	11	<,001
12	,371	,114	198,965	12	12	<,001
13	,156	,112	200,883	13	13	<,001
14	,224	,111	204,945	14	14	<,001
15	,075	,110	205,404	15	15	<,001
16	,073	,109	205,856	16	16	<,001

a. Procesul subiacent presupus este independența (zgomot alb).
b. Bazat pe aproximarea asimptotică chi-pătrat.

Sursa: prelucrare în SPSS

Seria de timp nestaționară poate fi transformată în serie staționară cu ajutorul operatorului diferență de un anumit ordin. Această transformare se poate realiza cu ajutorul SPSS (meniul forecasting, sequence chart, transform, difference 1). În Figura nr. 4 putem observa seria de date transformată în serie staționară de ordinul întâi (adică am aplicat operatorul o singură dată pentru a obține seria staționară).

Procesul ARIMA este determinat de 3 parametri - p, d și q - iar modelul se scrie sub forma:

$$ARIMA(p, d, q),$$

unde p reprezintă componenta autoregresivă (AR), d ordinul de integrare (I) și q componenta mediei mobile (MA).

Cum decidem parametrii pentru modelul ARIMA? Cu ajutorul funcției de autocorelație și autocorelație parțială pentru o serie staționară (seria noastră deja a fost transformată așa cum am descris mai sus), astfel:


- parametrul p se referă la numărul de valori trecute (decalaje sau lag-uri) pe care modelul le folosește pentru a face predicții (Gupta A., Mehta V., 2023) și se poate determina cu ajutorul funcției de autocorelație parțială, mai concret corelograma autocorelației parțiale (Figura nr. 6), pe care o obținem cu ajutorul SPSS. Pe baza acestui grafic observăm termenii care sunt semnificativ diferiți de zero;
- parametrul d se referă la numărul de diferențieri efectuate pentru a elimina nestacionaritatea (Gupta A.,

Mehta V., 2023) iar în cazul nostru este 1, deoarece operatorul de diferență utilizat mai sus este de ordinul 1;

- parametrul q se referă la numărul de termeni de eroare din trecut utilizați de un model ARIMA atunci

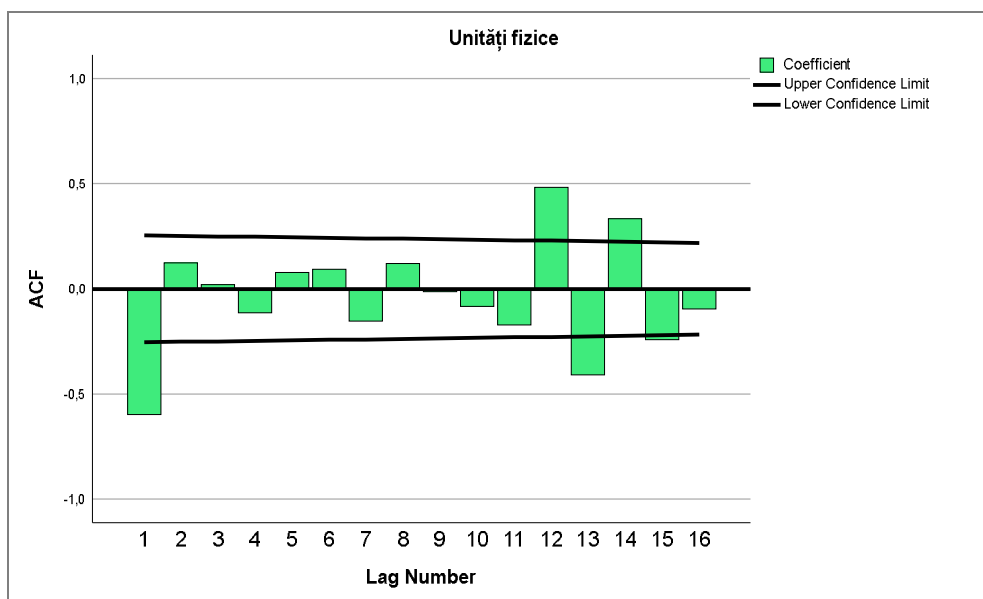
când facem predicții (Gupta A., Mehta V., 2023) și se poate determina cu ajutorul corelogramei de autocorelație (Figura nr. 5), unde observăm termenii care sunt semnificativ diferiți de zero;

Figura nr. 4. Transformare serie nestaționară în staționară de ordinul întâi




Sursa: prelucrare proprie în SPSS

Figura nr. 5. Corelograma autocorelației seriei transformate



Sursa: prelucrare proprie în SPSS

Figura nr. 6. Corelograma autocorelației parțiale seriei transformate



Sursa: prelucrare proprie în SPSS

Atunci când datele din model prezintă elemente de sezonaliitate vorbim de un model **ARIMA sezonier**, denumit și **SARIMA**. Datele din model înregistrează sezonaliitate în anumite perioade, atunci când sunt influențate de sărbătorile de sfârșit de an sau sărbătorile religioase (Devianto D., et al., 2024), de perioadele de vacanță unde, de exemplu industria aeriană, înregistrează cereri mai mari (Firat M., Kaplan Y.D., Sampli R., 2021). Și vânzările din retail pot înregistra sezonaliitate, cum ar fi industria alimentară din comerțul cu amănuntul (Nari Sivanandam N. A., Ahrens D., 2015) sau anumite echipamente care tind să aibă valori ridicate sau scăzute în timpul iernii, respectiv al verii (Noureen S., Atique S., Roy V., Bayne S., 2019).

Atunci când ARIMA încorporează, pe lângă sezonaliitate, și variabile externe în model (factori exogeni), adică se includ informații externe precum vremea, cursul de schimb etc. (Gupta A., Mehta V., 2023), vorbim de un model denumit **SARIMAX** (Nari Sivanandam N. A., Ahrens D., 2015).

La fel ca seriile temporale non-sezoniere, datele pot fi modelate și prognozate ca un proces ARIMA. Parametrii și modelul SARIMA se notează astfel (Noureen S., Atique S., Roy V., Bayne S., 2019):

$$\text{ARIMA}(p, d, q) (P, D, Q),$$

unde termenii p, d, q reprezintă componenta nesezonieră, iar termenii P, D, Q reprezintă componenta sezonieră a modelului.

În continuare putem reda corelograma autocorelației respectiv corelograma autocorelației parțiale seriei transformate (de ordin 1) SARIMA (Figurile nr. 7 și 8) pentru datele noastre, care au fost obținute cu ajutorul SPSS v30. Lag-urile corelogramelelor cu componenta sezonieră sunt prezentate cu o sezonaliitate din 12 în 12 luni (12, 24, 36). Aceste grafice ne vor ajuta să determinăm parametrii modelului.

Modelarea mediei mobile (parametrul MA) poate ridica probleme în practică: în acest caz, autorul Jemna D. (2009, p. 226) prezintă soluția de a testa și utiliza doar parametrul AR – p în model. Vom ține și noi cont de această informație la testarea modelelor.


Avem acum toate informațiile necesare pentru a identifica și testa modelele ARIMA și SARIMA în SPSS.

Literatura de specialitate ne îndeamnă, pentru selectarea modelelor, să nu utilizăm doar corelogramele, ci și alte tehnici, care înlătură o parte din subiectivitate în interpretarea ACF și PACF, denumite **criteriile informaționale**. Cele mai populare trei criterii sunt: criteriul informațional (AIC) al lui Akaike (1974), criteriul informațional bayesian (BIC) al lui Schwarz (1978) și criteriul Hannan-Quinn (HQIC), (Brooks C., 2008, p. 232-

233). Cel mai mic criteriu (valoare) BIC/AIC este de preferat (Tripti D., Shamshad A., Mohammad S., 2020).


SPSS ne oferă criteriul BIC pe care îl vom folosi și noi în analiza noastră.

Figura nr. 7. Corelogramele autocorelației seriei transformate (componenta nesezonieră și sezonieră)



Sursa: prelucrare proprie în SPSS

Figura nr. 8. Corelograma autocorelației parțiale seriei transformate (componenta nesezonieră și sezonieră)



Sursa: prelucrare proprie în SPSS

Pe lângă criteriile informaționale se pot utiliza **indicatori de acuratețe** (care măsoară valorile reale vs. cele previzionate), cum ar fi MAE (eroarea medie absolută), RMSE (eroare medie pătratică) și MAPE (procentajul mediu absolut al erorii); desigur indicatorul cu valorile cele mai mici poate reprezenta modelul cel mai potrivit (Ho J.S., Zhang Y., 2022). Noi vom alege să utilizăm MAPE, care exprimă rezultatele în valori relative.

Formula de calcul este redată mai jos (Sagaert Y. R., et. al, 2017):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{Y_{t+h} - Y'_{t+h}}{Y_{t+h}}, \text{ unde}$$

Y_{t+h} reprezintă datele reale (datele originale),
 Y'_{t+h} sunt valorile prognozate.

În **Tabelul nr. 2** redăm modelele propuse, care sunt ordonate după indicatorul MAPE (Mean Absolute Percentage Error).

Tabelul nr. 2. Modele propuse ARIMA și SARIMA (ordonate după indicatorul MAPE)								
Nr. crt	MODEL	MAPE (%)	BIC	R-squared	Coefficienții modelului (sig<0,05 pentru AR și MA)	Test Ljung-Box - staționaritatea erorilor (sig<0,05)	Observații - corelogramele erorilor modelului	Unități totale previzionate
0	-	(3,2% - 5,6%)	(11,43 - 12,78)	(51% - 79%)	-	-	-	(69.758 - 74.775 buc.)
1	SARIMA(2,1,3)(0,1,2)	3,202	11,571	0,675	nesemnificativi statistic	0,174	Erorile se află în interval	70.768
2	SARIMA(2,1,1)(0,1,2)	3,352	11,501	0,624	nesemnificativi statistic	0,089	Erorile se află în interval	71.811
3	SARIMA(1,1,3)(0,1,2)	3,451	11,656	0,606	nesemnificativi statistic	0,024	Erorile se află în interval	72.076
4	SARIMA(2,1,3)(0,1,0)	3,477	11,498	0,626	nesemnificativi statistic	0,34	Erorile se află în interval	70.127
5	SARIMA(2,1,1)(0,1,0)	3,579	11,442	0,593	semnificativi statistic	0,098	Erorile se află în interval	70.843
6	SARIMA(2,1,0)(0,1,2)	3,581	11,47	0,595	nesemnificativi statistic	0,006	Erorile se află în interval	70.907
7	SARIMA(1,1,3)(0,1,0)	3,631	11,572	0,552	nesemnificativi statistic	0,022	Erorile depășesc intervalul	70.665
8	SARIMA(1,1,1)(0,1,2)	3,635	11,527	0,572	nesemnificativi statistic	0,005	Erorile se află în interval	71.750
9	ARIMA(11,1,0)	3,71	12,134	0,784	nesemnificativi statistic	0,016	Erorile se află în interval	74.424
10	ARIMA(11,1,1)	3,741	12,718	0,793	nesemnificativi statistic	<,001	Erorile se află în interval	74.049
11	SARIMA(2,1,0)(0,1,0)	3,793	11,445	0,513	semnificativi statistic	0,01	Erorile se află în interval	69.758
12	ARIMA(2,1,12)	3,854	12,4	0,785	nesemnificativi statistic	<,001	Erorile se află în interval	71.926
13	SARIMA(1,1,1)(0,1,0)	3,872	11,433	0,519	nesemnificativi statistic	0,03	Erorile depășesc intervalul	70.341
14	ARIMA(2,1,14)	3,937	12,602	0,781	nesemnificativi statistic	<,001	Erorile depășesc intervalul	73.983
15	ARIMA(2,1,13)	4,218	12,702	0,735	nesemnificativi statistic	<,001	Erorile depășesc intervalul	73.119
16	ARIMA(2,1,1)	4,935	11,891	0,655	nesemnificativi statistic	<,001	Erorile depășesc intervalul	74.521
17	ARIMA(1,1,1)	4,946	11,807	0,654	nesemnificativi statistic	<,001	Erorile depășesc intervalul	74.520
18	ARIMA(2,1,0)	5,363	11,962	0,596	semnificativi statistic	<,001	Erorile se află în interval	73.879
19	ARIMA(1,1,0)	5,64	12,021	0,532	semnificativi statistic	<,001	Erorile depășesc intervalul	71.247

Sursa: prelucrare proprie

Observăm din **Tabelul nr. 2** faptul că pentru modelele analizate, MAPE are valorile cuprinse între 3,2% și 5,6%. Acest lucru reprezintă o precizie mare a prognozei modelelor (Seval E., Nursel O., 2017) așa cum putem observa din **Tabelul nr. 3**. La fel și valorile BIC sunt foarte apropiate între ele (11,43-12,78) iar R Squared (raportul de determinație care ne arată cât la sută din variația unităților fizice este influențată de variația variabilei timp) are valori cuprinse între 51% - 79%.

Tabelul nr. 3. Intervalele pentru MAPE și precizia previziunilor

Nr. crt.	Valori de referință - MAPE	Previziune
1	≤ 10%	Precizie mare
2	10% - 20%	Precizie bună
3	20% - 50%	Precizie fezabilă
4	≥50%	Precizie scăzută

Sursă: Seval E., Nursel O., 2017

După analiza indicatorilor, pentru alegerea modelului optim pentru previziune s-au luat în considerare mai multe criterii: coeficienții modelului (pentru un sig.<0,05 pentru AR și MA), rezultatele testului Ljung-Box privind staționaritatea erorilor modelului (pentru un sig.<0,05)

precum și analiza reziduurilor (zgomotul alb) a corelogramelor; aceste informații ne ajută să validăm modelul final.

Din **Tabelul nr. 2** putem deduce faptul că doar modele aflate pe rândul 5, 11, 18 și 19 au coeficienții semnificativi statistic (sig.<0,05) pentru AR (p) sau MA (q). Restul modelelor care au coeficienții nesemnificativi statistic (sig.>0,05) nu mai pot fi luate în considerare pentru predicție.

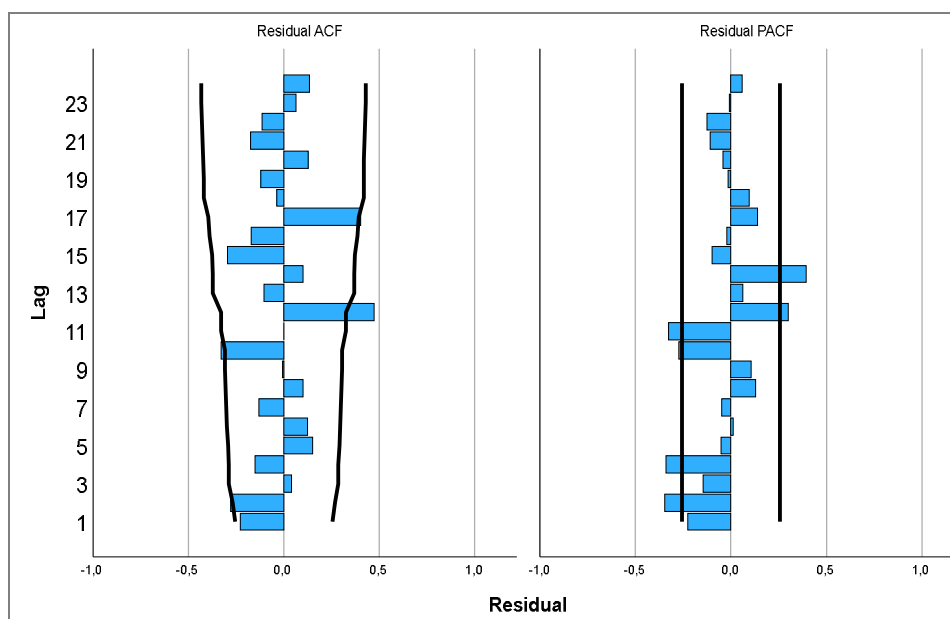
Procedăm mai departe cu analiza modelelor rămase, adică SARIMA(2,1,1)(0,1,0), SARIMA(2,1,0)(0,1,0), ARIMA(2,1,0) și ARIMA(1,1,0).

Modelul SARIMA(2,1,1)(0,1,0) aflat pe rândul 5 nu îndeplinește condiția privind staționaritatea erorilor modelului (sig.= 0,098 > 0,05), adică reziduurile sunt nestaționare.

SARIMA(2,1,0)(0,1,0) reprezintă un model ce poate fi utilizat (rândul 11), sig.= 0,01, adică erorile estimate ale modelului sunt staționare, iar conform reziduurilor corelogramelor, erorile se află în intervalul de încredere.

ARIMA(2,1,0) mai reprezintă un potențial model (rândul 18) cu un sig.<,001, adică erorile estimate ale modelului sunt staționare, iar reziduurile din corelograme se află în intervalul de încredere.

Figura nr. 9. Valorile reziduale pentru modelul ARIMA(1,1,0)



Sursa: prelucrare proprie în SPSS

Modelul ARIMA(1,1,0) aflat pe rândul 19, deși înregistrează un sig. <0,05, adică erorile estimate ale modelului sunt staționare, erorile corelogramelor depășesc intervalul de încredere, așa cum se poate observa din **Figura nr. 9**.

În final modelele SARIMA(2,1,0)(0,1,0) și ARIMA(2,1,0) îndeplinesc criteriile utilizate, însă pe care îl putem alege în final? Observăm din **Tabelul nr. 2** faptul că, deși se acceptă ipoteza de staționaritate a erorilor estimate pentru ambele modele, valoarea sig. este mai semnificativă pentru modelul ARIMA(2,1,0), adică sig.=<,001, comparativ cu SARIMA(2,1,0)(0,1,0) pentru care sig. este de 0,01.

Pe baza acestor argumente alegem modelul ARIMA(2,1,0) și mergem mai departe cu procesul de previziune.

Putem proceda acum la estimarea modelului ARIMA(2,1,0), prin intermediul programului SPSS v30, din meniul *Analyze, Forecasting, Create Traditional Models*.

Estimația parametrului autoregresiv este redată în **Tabelul nr. 4**. Observăm faptul că lag-ul 1 (adică variabila decalată utilizată drept predictor) este semnificativ pentru sig.= <,001 și lag-ul 2 este semnificativ pentru sig.= ,005.

Procedăm mai departe cu validarea modelului și verificăm ipotezele privind staționaritatea erorilor din model pentru un sig. <0,05.

H0: $\epsilon \neq 0$, erorile estimate ale modelului sunt *nestaționare*

H1: $\epsilon = 0$, erorile estimate ale modelului sunt *staționare*.

Conform testului Ljung-Box (din **Tabelul nr. 5**) rezultă că Sig este <,001, adică <0,05 → se respinge ipoteza H0 și se acceptă ipoteza H1, adică *se acceptă ipoteza de staționaritate a erorilor*.

Tabelul nr. 4. Parametrii modelului ARIMA (2,1,0)

ARIMA Model Parameters								
				Estimate	SE	t	Sig.	
Unități fizice- Model_1	Unități fizice	No Transformation	Constant	22,375	21,521	1,040	,303	
			AR	Lag 1	-,815	,125	-6,538	<,001
				Lag 2	-,366	,125	-2,937	,005
			Difference	1				

Sursa: prelucrare în SPSS

Tabelul nr. 5. Model statistic ARIMA (2,1,0)


Model Description									
			Model Type						
Model ID	Unități fizice	Model_1	ARIMA(2,1,0)						
Model Statistics									
Model	Model Fit statistics					Ljung-Box Q(18)			
	R-squared	RMSE	MAPE	MAE	Normalized BIC	Statistics	DF	Sig.	Number of Outliers
Unități fizice- Model_1	,596	356,799	5,363	293,430	11,962	64,230	16	<,001	<,001

Sursa: prelucrare în SPSS

Acest lucru este confirmat și cu ajutorul *corelogramelor* din **Figura nr. 10**, unde erorile se află în limita intervalului și nu diferă semnificativ de zero. Practic, ceea ce rămâne

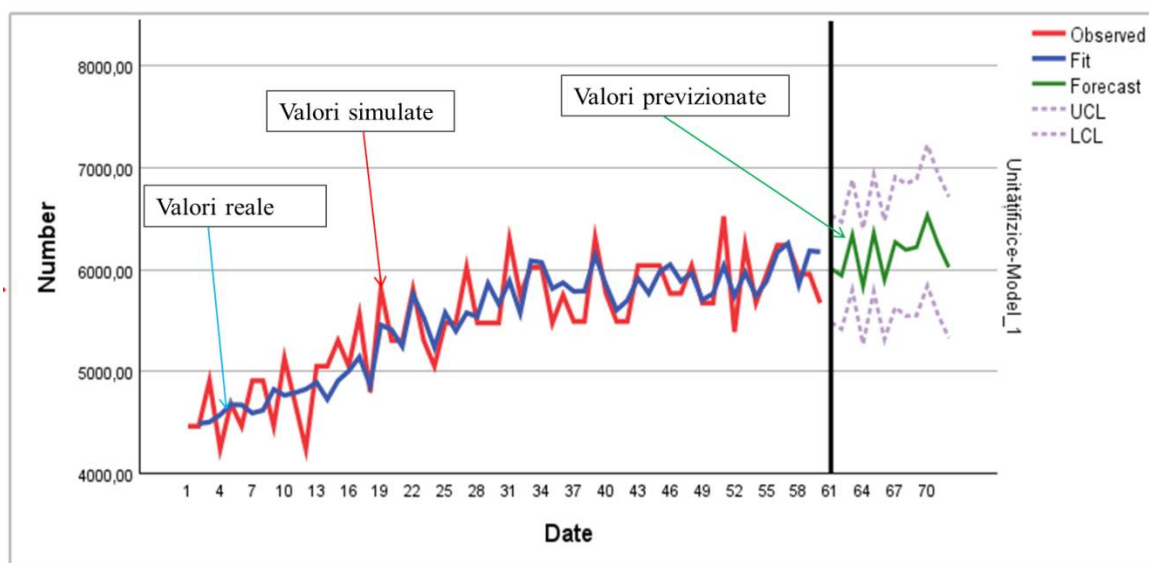
în acest interval (valori reziduale) reprezintă „*zgomotul alb*”, cu media 0 și dispersia 0, adică acea parte care nu poate fi prezisă și reprezintă factori necunoscuți.

Figura nr. 10. Valorile reziduale a modelului



Sursa: prelucrare proprie în SPSS

Figura nr. 11. Valorile reale, simulate și previzionate de model



Sursa: prelucrare proprie pe baza graficului obținut cu ajutorul SPSS

Conform rezultatelor prezentate în **Tabelul nr. 5** mai putem afirma faptul că 59,6% din variația volumelor de vânzări este influențată de variația variabilei timp.

În **Figura nr. 11** observăm valorile realizate ale seriei de date, valorile simulate de model precum și valorile previzionate care păstrează o tendință crescătoare.

Tabelul nr. 6. Valori previzionate pentru anul 2024 precum și valorile limitelor inferioare și superioare

YEAR_	MONTH_	DATE_	Predicted Unități fizice Model_1	LCL Unități fizice Model_1	UCL Unități fizice Model_1
2024	1	JAN 2024	6010	5483	6538
2024	2	FEB 2024	5943	5416	6469
2024	3	MAR 2024	6342	5800	6883
2024	4	APR 2024	5835	5268	6401
2024	5	MAY 2024	6361	5788	6933
2024	6	JUN 2024	5898	5315	6481
2024	7	JUL 2024	6271	5631	6910
2024	8	AUG 2024	6194	5546	6842
2024	9	SEP 2024	6221	5550	6891
2024	10	OCT 2024	6532	5841	7224
2024	11	NOV 2024	6248	5557	6940
2024	12	DEC 2024	6024	5332	6715
TOTAL			73.879	66.528	81.229

Sursa: date obținute în SPSS

Tabelul nr. 7. Bugetul de vânzări previzionat pentru anul 2024 (volum și venituri)

Buget 2024	01	02	03	04	05	06	07	08	09	10	11	12	Total 2024
Unități previzionate	6.010	5.943	6.342	5.835	6.361	5.898	6.271	6.194	6.221	6.532	6.248	6.024	73.879
Venituri previzionate	2.939.812 €	2.907.039 €	3.102.211 €	2.854.211 €	3.111.505 €	2.885.027 €	3.067.481 €	3.029.817 €	3.043.024 €	3.195.150 €	3.056.231 €	2.946.661 €	36.138.170 €

Sursa: prelucrare proprie

În **Tabelul nr. 6** redăm valorile obținute pe fiecare lună a anului 2024, precum și valorile încadrate în intervalul de încredere.

Volumele sunt apoi înmulțite cu prețul de vânzare și obținem, astfel, veniturile planificate din buget (**Tabelul nr. 7**).

4. Concluzii

Bugetul reprezintă instrumentul fundamental de planificare pe termen scurt (de obicei 1 an), orientat spre o gestiune previzională profitabilă. Obiectivele din buget trebuie să corespundă strategiei definite la nivelul entității traduse prin plan (Caraiani C., 2010, p. 37).

Previziunea reprezintă baza de pornire a bugetării. Astfel, a bugeta înseamnă a prevedea și a decide, iar a previziona înseamnă a cunoaște înainte de a acționa (Badea F., Dobrin C., 2006, p. 71 și 81). Drept urmare în acest studiu ne-am propus să proiectăm bugetul de

venituri plecând de la datele istorice ale unei companii din domeniul producției, ce privesc perioada 2019-2023, predicțiile realizându-se pentru anul 2024.

Cum putem obține previziunile? Cu ajutorul modelelor de previziune. Cele mai cunoscute și utilizate modele sunt: modelul seriilor de timp, cum ar fi exponential smoothing (netezire exponențială) și modelul ARIMA, modelul cauză-efect bazat pe relația dintre variabile independente (driver) și dependente și în final modelul critic utilizat atunci când nu avem date anterioare cu care putem lucra.

Pentru realizarea predicțiilor s-a utilizat modelul seriilor de timp ARIMA, iar primul pas a constat în transformarea seriei de date din nestaționară în staționară. Dacă lucrăm cu o serie nestaționară, există riscul apariției fenomenului de corelație artificială între variabile, adică nu există concret o legătură între acestea (Jemna D., 2009, p. 209-210). Pe baza corelogramelor autocorelației și autocorelației parțiale s-au identificat modele potențiale

ARIMA și SARIMA (ARIMA sezonier) care au fost apoi testate (cu ajutorul programului SPSS v30) și validate după mai multe criterii, cum ar fi indicatori de acuratețe (MAPE - eroarea medie absolută), criteriile informaționale (BIC - criteriul informațional bayesian), testul Ljung-Box privind staționaritatea erorilor (pentru $\text{sig} < 0,05$) și analiza reziduurilor corelogramelor (zgomotul alb). În final s-a validat modelul de tip ARIMA(2,1,0) care a previzionat un total de 73.879 unități fizice pentru anul 2024.

Volumele au fost apoi înmulțite cu prețul de vânzare și s-au obținut veniturile planificate. Acest model ne arată o creștere a unităților față de perioada 2019-2023, semn favorabil pentru companie în ceea ce privește creșterea veniturilor. Bineînțeles, acest lucru duce și la costuri mai mari cu producția, iar managementul trebuie să aibă în vedere un control și o gestiune asupra costurile directe.

Limitele studiului pot fi reprezentate de accesul limitat la date și informații cu privire

la practicile bugetare și obiectivele pe termen scurt ale companiei în cauză. Accesul restricționat la tot ce ține de planul strategic și strategiile companiei pentru următorii ani ar fi putut contribui și mai bine la proiectarea bugetului

de venituri pentru anul 2024. O altă limitare face referire la metodă, mai concret variabila independentă este reprezentată doar de factorul timp și nu s-au inclus în model alte variabile care pot influența vânzările în viitor.

În lucrarea de față pentru predicția bugetului de venituri s-au utilizat seriile de timp bazate pe modelul ARIMA. Previziunile se pot realiza, însă, și prin intermediul altor abordări statistice, care nu au fost utilizate, cum ar fi seriile de timp prin modelul numit exponential smoothing (netezire exponențială), care are rolul de a reduce decalajul dintre previziune și cerere în cazul schimbărilor neașteptate, RNN (rețele neuronale recurente) sau modelarea seriei pe trend (predicții realizate cu ajutorul analizei de regresie). Dacă se pot încorpora într-un model ARIMA aspecte privind sezonabilitatea și influența factorilor exogeni se poate dezvolta modelul denumit SARIMAX. Mai mult decât atât, se poate înlocui variabila timp cu alte variabile independente (atât interne, cât și externe companiei) care pot influența vânzările, cum ar fi nivelul veniturilor consumatorilor, nivelul inflației, structura populației, prețul produselor pe piață, bugetul publicității, informații despre competiție etc.

Bibliografie

- Anghelache C., Manole A. (2012) Seriile dinamice / cronologice (de timp) - prezentare teoretică, structură, relațiile dintre indici, *Romanian Statistical Review* nr. 10
- Badea F., Dobrin C. (2006) Gestiunea Bugetară a sistemelor de producție, *Ed. Economică*, București
- Brooks C. (2008) Introductory Econometrics for Finance, second edition, *Cambridge University Press*, New York
- Budugan D. (2001) Contabilitate și Control de Gestiune, *Ed. Sedcom Libris*, Iași
- Caraiani C., Dumitrana M., Dascălu C., Dumitru M., Glăvan M., Lungu C., Calu D., Jinga G., Gușe R., Jianu I., Vulpoi M. (2010) Control de Gestiune, *Ed. Universitară*, București
- Cărbunaru B.A. (2013) Băcescu Condruz M., Metode utilizate în analiza variațiilor sezoniere a seriilor cronologice, *Revista Română de Statistică*, nr. 3
- Chorafas D. N. (2006) IFRS, Fair Value and Corporate Governance, *Ed. Elsevier*, Oxford
- Devianto D., Permana D., Arif E., Afrimayani A., Yanuar Y., Maiyastri M., Yollanda M. (2024) An innovative model for capturing seasonal patterns of train passenger movement using exogenous variables and fuzzy time series, *Journal of Open Innovation: Technology, Market, and Complexity*, no.10
- Firat M., Kaplan Y.D., Sampli R. (2021) Forecasting Air Travel Demand for Selected Destinations Using Machine Learning Methods, *Journal of Universal Computer Science*, vol. 27, no. 6 (2021), 564-581
- Gupta A., Mehta V. (2023) Time Series based Predictive Model for Analysing the Health of Power transformer, *International Conference on Innovative Data Communication Technologies and Application (ICIDCA)*, Uttarakhand, India, 2023, pp. 1006-1013, doi: 10.1109/ICIDCA56705.2023.10099709
- Guță A.J., Catrina I. (2020) Forecast activity in the context of the dynamics of economic and social processes and phenomena, *Annals of the University of Petroșani, Economics*, 20(1), 115-124
- Ho J.S., Zhang Y. (2022) Forecasting Road Traffic Fatalities in Malaysia Using Seasonal Autoregressive Integrated Moving Average (SARIMA) Model, *Journal of Science and Technology*, DOI: 10.47836/pjst.30.2.03
- Horvath P., Binder B.C.K, Currel M., Esser J., Gerdes S., Graf J., Greiner O., Grunebaum D., Heinzelmann M., Hofmann., Hohner M.A., Kammler-Burra A., Leyk J., Link M., Muller M., Sasse A., Scheffner J., Schmidt H. (2009) Controlling - Sisteme eficiente de creștere a performanței firmei, Ed. a II-a, *Ed. C.H. Beck*, București

14. Jain L.D.C, Malehorn J. (2006) Benchmarking: Forecasting Practices: A Guide to Improving Forecasting Performance, Ed. Graceway Publishing Company, NW
15. Jemna D. (2009) Econometrie, Ed. Sedcom Libris, Iași
16. Libby T., Lindsay R.M. (2010) Beyond Budgeting or Budgeting Reconsidered? A Survey of North-American Budgeting Practice, *Management Accounting Research*, 21, 56-75. <http://dx.doi.org/10.1016/j.mar.2009.10.003>
17. Nica P., Iftimescu A. (2008) Management. Concepte și Aplicații, Ed. Sedcom Libris, Iași
18. Noureen S., Atique S., Roy V., Bayne S. (2019) Analysis and application of seasonal ARIMA model in Energy Demand Forecasting: A case study of small scale agricultural load, *IEEE 62nd International Midwest Symposium on Circuits and Systems (MWSCAS)*, Dallas, TX, USA, pp. 521-524, doi: 10.1109/MWSCAS.2019.8885349
19. Rachlin R. (2007) Sistemul complet de bugete ale firmei, Ed. BMT Publishing House, București
20. Sagaert Y.R., Aghezzaf EL-H., Kourentzes N., Desmet B. (2017) Tactical sales forecasting using a very large set of macroeconomic indicators, *European Journal of Operational Research*
21. Seval E., Nursel O. (2017) Grey modelling based forecasting system for return flow of end-of-life vehicles, *Technological Forecasting & Social Change* 115, pp. 155–166
22. Sivanandam N. A., Ahrens D. (2015) A Hybrid Seasonal Autoregressive Integrated Moving Average and Quantile Regression for Daily Food Sales Forecasting, *Intern. Journal of Production Economics*, <http://dx.doi.org/10.1016/j.ijpe.2015.09.039>
23. Tripti D., Shamshad A., Mohammad S. (2020) Time series analysis of climate variables using seasonal ARIMA approach, *J Earth Syst Sci* 129, 149, <https://doi.org/10.1007/s12040-020-01408-x>
24. Zamfir M. (2017) Controlul de gestiune prin sistemul de bugete, Ed. Pro Universitaria, București
25. Zhao L., Mbachu J., Zhang H. (2019) Forecasting residential building costs in New Zealand using a univariate approach, *International Journal of Engineering Business Management*, Volume 11: 1–13, <https://doi.org/10.1177/184797901988006>.