

Dana Rad, Remus Runcan

ANALIZA STATISTICĂ APLICATĂ ÎN ASISTENȚĂ SOCIALĂ, ȘTIINȚELE EDUCAȚIEI ȘI PSIHOLOGIE

Corelații, regresii și modele de mediere

Presa Universitară Clujeană

ANALIZA STATISTICĂ
APLICATĂ ÎN ASISTENȚĂ SOCIALĂ,
ȘTIINȚELE EDUCAȚIEI ȘI PSIHOLOGIE

Corelații, regresii și modele de mediere

DANA RAD | REMUS RUNCAN

DANA RAD este Doctor în Psihologie al Universității Babeș-Bolyai din Cluj-Napoca cu tema „Gestiunea resurselor umane prin tehnici Fuzzy”. În prezent, este Prof. univ. dr. la Universitatea “Aurel Vlaicu” din Arad și coordonator de doctorate în domeniul Asistență Socială. Domeniile sale de interes științific: metodologia cercetării, statistică aplicată, ingineria sistemelor sociale.

REMUS RUNCAN este Doctor în Sociologie al Universității de Vest din Timișoara cu tema „Comunicarea virtuală și influențele ei asupra relațiilor umane: Capcanele Facebook-ului”. În prezent, este Prof. univ. dr. la Universitatea “Aurel Vlaicu” din Arad și coordonator de doctorate în domeniul Asistență Socială. Domeniile sale de interes științific: comunicare, asistență socială, metodologia cercetării, familie, parentalitate, adolescență și rețele virtuale.

DANA RAD | REMUS RUNCAN

**ANALIZA STATISTICĂ
APLICATĂ ÎN ASISTENȚĂ SOCIALĂ,
ȘTIINȚELE EDUCAȚIEI ȘI PSIHOLOGIE**

Corelații, regresii și modele de mediere

PRESA UNIVERSITARĂ CLUJEANĂ

2025

Referenți științifici:

Prof. univ. dr. Loredana Vișcu

Conf. univ. dr. Ioana Eva Cădăriu

**Autorii au contribuții egale
în elaborarea lucrării.**

ISBN 978-606-37-2506-7

**© 2025 Autorii volumului. Toate drepturile rezervate.
Reproducerea integrală sau parțială a textului, prin orice
mijloace, fără acordul coordonatorilor, este interzisă și se
pedepsește conform legii.**

**Universitatea Babeș-Bolyai
Presa Universitară Clujeană
Director: Codruța Săcelean
Str. B.P. Hasdeu nr. 51
400371 Cluj-Napoca, România
Tel.: (+40)-744.687.884
E-mail: editura@ubbcluj.ro
<http://www.editura.ubbcluj.ro/>
<https://biblioteca.ubbcluj.ro/>**

Cuprins

Prefață	7
CAPITOLUL 1. Introducere în analiza statistică aplicată	9
1.1. Rolul statisticii în științele educației, psihologie și asistență socială.	11
1.2. Scopuri și obiective ale analizelor corelaționale și de regresie.....	15
1.3. Etapele procesului de analiză statistică și aplicații practice	18
CAPITOLUL 2. Fundamentele analizei corelaționale	23
2.1. Tipuri de corelații: Pearson, Spearman, Kendall și corelații parțiale	25
2.2. Calcularea și interpretarea coeficienților de corelație	28
2.3. Limitări și erori comune în interpretarea corelațiilor	31
CAPITOLUL 3. Modele de regresie liniară simplă	35
3.1. Concepte fundamentale și asumțiile regresiei liniare simple	36
3.2. Interpretarea coeficienților de regresie și semnificația acestora	38
3.3. Aplicarea regresiei pentru predicția rezultatelor și verificarea modelului.....	40
CAPITOLUL 4. Regresia liniară multiplă și non-liniară (pătratică – curbilinie).....	43
4.1. Construcția și interpretarea modelelor de regresie multiplă	45
4.2. Regresia polinomială și logistică: definiție și aplicații.....	48
4.3. Testarea asumțiilor și optimizarea modelelor de regresie complexă.....	51

CAPITOLUL 5. Introducere în mediere: simplă, paralelă, secvențială	54
5.1. Conceptul de mediere: înțelegerea variabilelor intermediare.....	57
5.2. Medierea simplă: metode de analiză și interpretare a efectelor indirecte	60
5.3. Modele de mediere paralelă și secvențială: diferențe și aplicații practice.....	63
 CAPITOLUL 6. Medierea moderată: concepte și aplicabilitate	67
6.1. Definirea și utilizarea modelelor de mediere moderată.....	68
6.2. Identificarea și interpretarea interacțiunilor dintre variabile	71
6.3. Aplicații ale medierii moderate în științele sociale și implicațiile rezultatelor	74
 CAPITOLUL 7. Instrumente și software pentru analiza statistică.....	77
7.1. Prezentarea principalelor software-uri: SPSS, JASP, JAMOVI.....	77
7.2. Tutoriale aplicative pentru analize corelaționale și de regresie	79
7.3. Ghid practic pentru utilizarea software-urilor în analize de mediere și moderare	100
 CAPITOLUL 8. Interpretarea și prezentarea rezultatelor în cercetare ...	139
8.1. Structura unui raport statistic: cum să organizezi și să interpretezi datele	139
8.2. Raportarea corectă a statisticilor în științele sociale (standarde APA).....	141
8.3. Formularea concluziilor și utilizarea rezultatelor în contextul cercetării	143
 Bibliografie.....	145

Prefață

Această carte reprezintă un ghid cuprinzător destinat cercetătorilor, practicienilor și studenților interesați de utilizarea avansată a statisticii în analiza datelor din domenii sociale și comportamentale. Printr-o abordare integrată, cartea își propune să ofere o înțelegere profundă a metodelor statistice esențiale, precum corelațiile, regresiile și modelele de mediere, ilustrate cu exemple practice relevante pentru domeniile psihologiei, educației și asistenței sociale.

Statistica este mai mult decât o colecție de tehnici matematice; aceasta constituie o abordare metodologică menită să dezvăluie relații semnificative între variabile și să ofere răspunsuri obiective la întrebările de cercetare. Într-o eră în care deciziile bazate pe date sunt din ce în ce mai valoroase, competențele în analiza statistică devin esențiale pentru a genera concluzii valide și pentru a fundamenta intervenții eficiente. Cartea de față urmărește să simplifice complexitatea acestor metode, fără a compromite rigoarea științifică, printr-o combinație de explicații teoretice, aplicații practice și studii de caz specifice.

Structura lucrării reflectă o progresie logică, pornind de la fundamentele analizei corelaționale, continuând cu regresia liniară simplă și multiplă, și culminând cu modelele avansate de mediere și moderare. În cadrul fiecărui capitol, cititorul va găsi explicații detaliate ale conceptelor teoretice, metode de calcul, interpretări ale rezultatelor și exemple concrete de aplicare în domeniile psihologiei, educației și asistenței sociale. De asemenea, o atenție specială este acordată utilizării software-urilor statistice precum SPSS, JASP și Jamovi, care simplifică procesul analitic și permit o vizualizare clară a rezultatelor.

Importanța acestei lucrări constă și în accentul pus pe evitarea erorilor comune în analiza și interpretarea statistică. Discuțiile privind respectarea asumpțiilor statistice, dimensiunea eșantionului și impactul factorilor contextuali asigură o înțelegere completă și aplicabilă a metodelor

prezentate. În plus, cartea oferă o perspectivă critică asupra limitărilor inerente ale metodelor statistice și propune direcții pentru cercetări viitoare, contribuind astfel la dezvoltarea unei gândiri analitice riguroase.

Capitolele incluse oferă o acoperire tematică diversă. Primele capitole introduc fundamentele statisticii aplicate și explică rolul acestora în cercetările din psihologie, educație și asistență socială. Următoarele capitole se concentrează pe metodele de corelație și regresie, ilustrând aplicațiile lor în analiza relațiilor dintre variabile, predicția comportamentelor și evaluarea intervențiilor. Modelele de mediere și moderare, prezentate în detaliu, subliniază complexitatea proceselor psihologice și sociale și demonstrează utilitatea statisticii avansate în descifrarea acestor procese. Capitolul final abordează interpretarea și prezentarea rezultatelor, oferind cititorilor ghiduri practice pentru redactarea rapoartelor statistice conform standardelor APA.

Această carte este ancorată în domeniul științelor sociale, oferind analize și exemplificări pentru acesta, respectiv pentru domeniul științelor sociale, psihologie, științele educației și asistență socială. Astfel, lucrarea este concepută pentru a răspunde nevoilor unui public larg, incluzând cercetători care doresc să își aprofundeze cunoștințele metodologice, studenți care își construiesc o bază solidă în analiza statistică și practicieni interesați de aplicarea acestor metode în contexte profesionale.

Dr. Dana Rad și Dr. Remus Runcan

CAPITOLUL 1.

Introducere în analiza statistică aplicată

Analiza statistică a devenit o piatră de temelie în științele educației, psihologie și asistență socială, constituind unealta prin care cercetătorii și practicienii pot descifra tipare și relații ascunse în datele complexe ce caracterizează aceste domenii. Dacă ne imaginăm aceste domenii ca un ocean vast, plin de variabile și fenomene complexe, statistica este farul care ghidează căutătorii de adevăr prin valurile de informații și incertitudini. Ea nu doar iluminează și clarifică, ci ajută și la navigarea către decizii fundamentate și soluții informate. Statisticile permit celor care lucrează în educație, psihologie și asistență socială să transforme intuițiile în concluzii bazate pe dovezi și să aprofundeze înțelegerea unor fenomene aparent intangibile.

Folosirea statisticii în aceste domenii este deosebit de importantă deoarece atât educația, cât și psihologia și asistența socială se bazează pe înțelegerea comportamentului uman și a interacțiunilor sociale, fenomene care sunt rareori simple sau liniar predictibile. Statisticile permit astfel o explorare riguroasă și precisă a acestor dinamici, oferind un cadru prin care se poate evalua și măsura impactul intervențiilor sau relațiile dintre variabile aparent disparate. Privite ca un limbaj comun, statisticile sunt instrumentul prin care oamenii de știință și practicienii pot comunica și interpreta rezultatele într-un mod obiectiv și replicabil.

În educație, de exemplu, statisticile sunt utilizate pentru a măsura eficiența metodelor de predare, pentru a evalua progresul studenților și pentru a determina care factori contribuie cel mai mult la performanța academică. Analiza statistică poate răspunde la întrebări importante: Care metodă de predare este cea mai eficientă? Care sunt caracteristicile studenților care au nevoie de sprijin suplimentar? Cum influențează mediul familial performanța școlară? Aceste întrebări necesită răspunsuri bazate pe date și analize statistice riguroase, pentru a asigura o fundamentare solidă a deciziilor educaționale. Astfel, statisticile devin un instrument esențial

pentru îmbunătățirea calității procesului educațional și pentru dezvoltarea unor politici educaționale eficiente (Stevens, 2002).

În psihologie, statistica permite investigarea și măsurarea unor concepte abstracte, cum ar fi inteligența, personalitatea, emoțiile și motivația. Statisticile sunt fundamentale în cercetările psihologice deoarece oferă metode prin care datele colectate de la indivizi sau grupuri pot fi transformate în rezultate obiective și măsurabile. De exemplu, în evaluarea eficienței unei intervenții terapeutice, analiza statistică poate arăta dacă metoda terapeutică are efectul dorit asupra unui grup de participanți și dacă acest efect este semnificativ din punct de vedere statistic. Prin utilizarea statisticii, psihologii pot valida ipoteze și pot contribui la dezvoltarea unor teorii robuste care explică și prezic comportamentul uman (Cowles, 2005).

Asistența socială, prin natura sa, implică lucrul cu indivizi și grupuri care se confruntă cu diverse probleme și provocări. Statisticile oferă asistenților sociali instrumentele necesare pentru a înțelege mai bine impactul intervențiilor lor asupra clienților și pentru a optimiza resursele în favoarea celor care au cea mai mare nevoie de ele. De exemplu, analizele statistice pot fi folosite pentru a evalua efectul unui program de reabilitare asupra recidivei criminale sau pentru a măsura impactul suportului social asupra bunăstării emoționale a clienților. Statisticile oferă asistenților sociali posibilitatea de a cuantifica efectele acțiunilor lor și de a-și calibra intervențiile în funcție de rezultate concrete, astfel încât să răspundă mai eficient nevoilor comunității (Pituch & Stevens, 2015).

Statisticile oferă astfel o perspectivă detaliată asupra interacțiunilor dintre variabile și permit cuantificarea acestor relații în moduri care altfel ar fi imposibil de realizat. În toate aceste domenii, statistica este asemenea unei lentile care mărește detaliile fine ale relațiilor complexe, ajutând cercetătorii și practicienii să identifice tiparele și să prezică comportamentele. Statisticile permit cuantificarea, descrierea și interpretarea unor aspecte greu observabile direct, ajutând la construirea unui corpus de cunoștințe bazate pe dovezi.

Pentru studenții care încep studiul statisticii în aceste domenii, poate părea inițial o provocare copleșitoare. Statisticile implică un limbaj tehnic și un set de instrumente matematice care necesită timp și practică pentru a fi stăpânite. Însă, o înțelegere solidă a statisticii reprezintă o componentă esențială a pregătirii lor, deoarece le oferă capacitatea de a interpreta și de a

pune în practică cercetări relevante pentru profesiile lor. Statisticile sunt, în esență, limbajul prin care acești profesioniști își pot valida observațiile, pot fundamenta ipotezele și pot demonstra eficacitatea intervențiilor. Ca atare, cunoașterea statisticii devine o formă de alfabetizare esențială, fără de care nu poate exista o analiză profundă și riguroasă a fenomenelor studiate.

Astfel, acest ghid își propune să aducă mai aproape de studenți și cercetători conceptele fundamentale ale statisticii aplicate în educație, psihologie și asistență socială, într-un mod structurat și accesibil. Scopul principal este de a transforma statistica într-un instrument intuitiv și folositor pentru investigarea și înțelegerea complexităților din aceste domenii, mai degrabă decât într-o barieră tehnică dificil de depășit. Ghidul va explora diverse metode de analiză statistică, pornind de la cele mai simple tehnici descriptive și corelaționale până la modelele de regresie complexe și analiza mediatoarelor și moderatoarelor, oferind o bază solidă de cunoștințe și abilități necesare.

Această introducere ar trebui să inspire studenții să privească statistica nu doar ca pe o disciplină obligatorie, ci ca pe o unealtă vitală pentru explorarea și descifrarea comportamentelor umane și a structurilor sociale complexe.

1.1. Rolul statisticii în științele educației, psihologie și asistență socială

Statisticile joacă un rol crucial în îmbunătățirea înțelegerii fenomenelor sociale și psihologice printr-o metodologie structurată și empirică. Statisticile nu sunt doar o unealtă de măsurare, ci funcționează ca un limbaj universal care permite cercetătorilor din diverse domenii să interpreteze datele într-un mod precis și să construiască relații bazate pe evidențe. În științele educației, psihologie și asistență socială, acest limbaj statistic permite crearea unor structuri și modele care reflectă realitatea socială și psihologică, facilitând identificarea factorilor care influențează comportamentul și dezvoltarea umană (Stevens, 2002).

În psihologie, statisticile sunt fundamentale pentru interpretarea rezultatelor experimentale și pentru validarea teoriilor comportamentale. De exemplu, pentru a înțelege efectul unui anumit tip de terapie asupra anxietății, este esențial ca psihologii să utilizeze metode statistice pentru a determina dacă rezultatele sunt semnificative din punct de vedere statistic și

pot fi generalizate la o populație mai mare (Cowles, 2005). Statistica permite, de asemenea, testarea ipotezelor în mod riguros, ceea ce este crucial într-un domeniu în care variabilele psihologice pot fi greu de măsurat direct și sunt adesea influențate de multiple aspecte contextuale. În cercetările psihologice, metodologia statistică face posibilă atât înțelegerea trăsăturilor individuale cât și a dinamicii de grup, încurajând o abordare bazată pe dovezi în diagnosticare și intervenție (Aiken et al., 1990).

De-a lungul timpului, psihologia a evoluat ca disciplină științifică bazată pe cercetare empirică, iar statisticile au jucat un rol important în această tranziție. Ele au permis psihologilor să transforme observațiile subiective în date măsurabile și obiective. Metodele statistice cum ar fi corelația, regresia și analiza factorială au revoluționat modul în care psihologii pot analiza complexitatea fenomenelor mentale, oferind o cale de a testa teorii despre personalitate, cogniție și emoții (Chase & Chase, 1976). În prezent, statistica este considerată o componentă indispensabilă în formarea psihologilor, iar educația în acest domeniu începe devreme, pregătindu-i pe studenți să utilizeze instrumente statistice avansate pentru cercetări aplicate.

În educație, statistica este un element cheie pentru evaluarea eficacității metodelor de predare, a intervențiilor educaționale și a politicilor instituționale. Statisticile ajută la identificarea factorilor care contribuie la succesul academic, precum și la măsurarea impactului diferitelor metode de învățare asupra progresului elevilor. Analiza statistică este esențială pentru a înțelege și a optimiza experiența educațională, fie că este vorba de evaluarea performanței individuale sau de analiza generală a sistemului educațional (Pituch & Stevens, 2015). În acest sens, statisticile permit educatorilor să răspundă la întrebări fundamentale precum: „Care metodă de predare este cea mai eficientă pentru anumite categorii de elevi?” sau „Ce rol au resursele socio-economice în succesul școlar?”

În educație, utilizarea statisticilor facilitează nu doar evaluarea intervențiilor existente, ci și fundamentarea unor politici educaționale informate. De exemplu, o analiză statistică a rezultatelor obținute de elevi în urma aplicării unei noi metode didactice poate oferi informații despre eficiența acesteia, indicând dacă ar trebui adoptată pe scară largă. Statisticile permit astfel o abordare sistematică și empirică a învățării, contribuind la o înțelegere mai profundă a procesului educațional și la crearea unui mediu

de învățare optimizat. În plus, statisticile sunt folosite și pentru a evalua diferențele de performanță între elevi și pentru a identifica nevoile speciale ale acestora, contribuind astfel la o abordare personalizată și incluzivă a educației.

În asistența socială, analiza statistică permite o abordare structurată a intervențiilor și a programelor sociale, fiind crucială pentru evaluarea impactului acestora asupra bunăstării indivizilor și comunităților. Practicienii din asistența socială folosesc statistici pentru a măsura eficiența programelor de sprijin, a serviciilor sociale și a intervențiilor psihosociale (Lawless & Kulikowich, 2006). Statistica facilitează o evaluare obiectivă a efectelor acestor intervenții, asigurând astfel că resursele sunt alocate eficient și că programele sunt optimizate pentru a avea un impact maxim. În asistența socială, statisticile devin un „barometru” pentru bunăstarea populației, oferind o imagine de ansamblu asupra nevoilor și problemelor cu care se confruntă grupurile vulnerabile.

O componentă centrală a asistenței sociale este evaluarea și monitorizarea, iar statistica permite cuantificarea progresului clienților și măsurarea gradului de succes al intervențiilor. De exemplu, o analiză statistică a ratei de recidivă în rândul persoanelor care au beneficiat de un program de reabilitare poate oferi date concrete despre eficiența aceluiași program și poate ajuta la îmbunătățirea lui. Statisticile permit asistenților sociali să identifice corelații între diferite variabile, cum ar fi mediul familial, statutul socio-economic și sănătatea mentală, pentru a înțelege mai bine contextul în care aceștia acționează. Astfel, statistica devine un instrument esențial pentru practicienii din asistența socială, ajutându-i să fundamenteze deciziile pe baze concrete și să elaboreze intervenții adaptate nevoilor comunității.

Pentru studenții din aceste domenii, înțelegerea statisticii este esențială deoarece le oferă un set de instrumente și competențe care îi ajută să interpreteze date și să ia decizii fundamentate pe dovezi. Formarea în statistică este necesară încă din primii ani de studiu, pentru a-i ajuta pe studenți să devină familiarizați cu conceptele și metodele statistice și pentru a le permite să utilizeze aceste instrumente în mod independent în cercetările lor. Studiul lui Aiken et al. (1990) subliniază importanța unei educații solide în statistică, arătând că abilitățile statistice sunt esențiale pentru succesul în

cercetare, iar nevoia de specializare în acest domeniu este în continuă creștere.

Pentru studenții din psihologie, de exemplu, statisticile devin o „a doua limbă”, un mod de a comunica și de a înțelege comportamentele și emoțiile umane prin intermediul numerelor și al analizelor cantitative (Lalonde & Gardner, 1993). De asemenea, pentru studenții din științele educației, statisticile sunt un instrument valoros care le permite să analizeze eficiența metodelor pedagogice și să optimizeze procesul educațional pe baza datelor colectate în mod sistematic. În asistența socială, formarea în statistică este la fel de importantă, deoarece permite viitorilor asistenți sociali să dezvolte programe mai eficiente și să evalueze impactul acestora în mod obiectiv (Chase & Chase, 1976).

Pentru a asigura o pregătire adecvată, acest ghid își propune să ofere studenților o bază solidă în statisticile aplicate în cele trei domenii, concentrându-se pe exemple și aplicații practice care să ilustreze relevanța acestor metode în contextul specific al educației, psihologiei și asistenței sociale. Prin această abordare, studenții vor putea să înțeleagă statisticile nu doar ca pe un instrument teoretic, ci ca pe o unealtă esențială în rezolvarea problemelor și în fundamentarea deciziilor în activitatea lor viitoare.

Așadar, statisticile sunt esențiale în științele educației, psihologie și asistență socială, nu doar ca metodă de analiză a datelor, ci ca o limbă comună, care permite profesioniștilor din aceste domenii să interpreteze și să comunice informațiile într-un mod structurat și obiectiv. Statisticile nu doar sprijină interpretarea rezultatelor cercetării, ci și fundamentarea intervențiilor și a politicilor, ajutând la identificarea soluțiilor cele mai potrivite pentru diversele probleme din educație, psihologie și asistență socială. În acest sens, formarea în statistică și aplicarea acesteia devin parte integrantă a pregătirii profesionale pentru studenți și cercetători, consolidându-le abilitățile și încrederea în utilizarea acestor metode pentru a contribui pozitiv în carierele lor.

Acest subcapitol demonstrează că statisticile nu sunt doar o simplă unealtă matematică, ci un sistem de valori fundamentale și rigurozitate metodologică. Prin intermediul acestui ghid, studenții vor avea oportunitatea de a se familiariza cu metodele statistice și de a învăța cum să le aplice în mod corect și relevant în cercetările și practica lor. În ansamblu, cunoștințele statistice îmbunătățesc capacitatea de a înțelege și de a acționa

în beneficiul societății, contribuind la progresul general al științelor educației, psihologiei și asistenței sociale.

1.2. Scopuri și obiective ale analizelor corelaționale și de regresie

Analizele corelaționale și de regresie sunt două dintre cele mai importante metode statistice utilizate în științele sociale și comportamentale pentru a explora și a înțelege relațiile dintre variabile. Ele sunt unelte esențiale prin care cercetătorii descoperă tiparele și relațiile dintre fenomene complexe, permițând o înțelegere mai profundă a interdependențelor care influențează comportamentul uman. Analiza corelațională și regresia funcționează ca două „lupe de mărit”, fiecare având rolul său specific: analiza corelațională dezvăluie asocieri între variabile, în timp ce regresia oferă o înțelegere mai profundă a relațiilor cauzale. Acest subcapitol explorează rolurile, scopurile și aplicabilitatea acestor metode, ilustrând modul în care ele pot susține luarea deciziilor informate în educație, psihologie și asistență socială.

Analiza corelațională este o metodă statistică utilizată pentru a identifica relațiile reciproce dintre variabile fără a implica neapărat o legătură cauzală directă între ele (Howitt & Cramer, 2008). Scopul principal al analizei corelaționale este de a măsura gradul de asociere dintre două sau mai multe variabile și de a cuantifica această relație într-o manieră care permite cercetătorilor să înțeleagă mai bine structura datelor. Această metodă este adesea folosită în studiile exploratorii și observationale, unde cercetătorii nu pot manipula variabilele, dar vor să înțeleagă interdependențele naturale dintre acestea (Coetzee & Merwe, 2010).

De exemplu, o corelație între nivelul de educație și satisfacția în carieră poate sugera că indivizii cu un nivel educațional mai ridicat au o satisfacție mai mare la locul de muncă, fără ca această asociere să implice automat o relație cauzală. Această legătură poate furniza cercetătorilor o perspectivă asupra factorilor care ar putea fi investigați în mod mai detaliat prin alte metode. Astfel, analiza corelațională servește ca un punct de plecare pentru descoperirea de noi relații care merită explorate prin metode statistice mai avansate (Privitera, 2023).

Statisticile corelaționale au un avantaj distinct în faptul că ele oferă o măsură directă a gradului de asociere între variabile, prin coeficienți de

corelație precum Pearson, Spearman sau Kendall, care permit interpretarea asocierii sub diverse forme. Utilizarea analizei corelaționale în educație poate ajuta, de exemplu, la înțelegerea relației dintre atitudinile elevilor față de studiu și performanța academică, oferind o bază empirică pentru intervenții educaționale care să îmbunătățească motivația și performanța. În psihologie, analiza corelațională este adesea utilizată pentru a examina relații între variabile cum ar fi starea de bine și suportul social, oferind o privire de ansamblu asupra modului în care diverși factori psihologici se influențează reciproc.

În contrast cu analiza corelațională, care explorează asocierile între variabile, analiza de regresie oferă cercetătorilor posibilitatea de a estima relațiile cauzale dintre variabile, fiind esențială pentru construirea modelelor predictive (Sachs, 2012). Regresia ajută la identificarea variabilelor independente care au un impact asupra unei variabile dependente, oferind o înțelegere mai aprofundată a modului în care factorii de interes influențează rezultatele și permițând formularea de predicții. În esență, scopul regresiei este de a modela relația dintre o variabilă dependentă și una sau mai multe variabile independente, în vederea estimării unor efecte și a unor relații de influență.

Un exemplu clasic de analiză de regresie în domeniul educațional poate implica analiza factorilor care influențează rezultatele la examenele standardizate, cum ar fi mediul familial, motivația și metodele de predare. Regresia permite cercetătorilor să cuantifice contribuția fiecărui factor și să dezvolte intervenții care să răspundă în mod specific nevoilor educaționale ale elevilor. Prin această abordare, se poate determina, de exemplu, că mediul familial influențează performanța academică, dar și că această influență este semnificativă doar în combinație cu motivația intrinsecă a elevului (Gordon, 2012).

Regresia este utilizată extensiv și în asistența socială, unde poate ajuta la evaluarea eficacității programelor și intervențiilor. De exemplu, analiza de regresie poate determina în ce măsură un program de consiliere are un impact asupra recidivei criminale în rândul persoanelor eliberate condiționat. Astfel, regresia oferă o metodă de analiză care nu doar măsoară asocierea dintre variabile, ci și permite o înțelegere mai profundă a interacțiunilor și efectelor care contribuie la modificarea unor comportamente sau atitudini. Aceste informații sunt deosebit de utile pentru

dezvoltarea unor politici informate și eficiente, bazate pe date concrete (Roth, 1994).

Atât analiza corelațională, cât și regresia sunt extrem de utile în practică, permițând o diversitate de aplicații în cercetare. Corelația ajută la descoperirea asocierilor dintre variabile, care pot sugera direcții de cercetare viitoare sau pot susține teorii existente. De exemplu, o corelație pozitivă între succesul academic și motivația intrinsecă a elevilor poate servi drept fundament pentru intervenții educaționale care încurajează dezvoltarea acestei motivații. În domeniul asistenței sociale, corelațiile pot ajuta la înțelegerea legăturilor dintre statutul socio-economic și sănătatea mentală, oferind o bază pentru programe de sprijin specifice grupurilor vulnerabile (Howitt & Cramer, 2008).

Pe de altă parte, regresia este indispensabilă în construirea de modele predictive care permit prognoza și evaluarea impactului diverselor variabile asupra unei variabile de interes. Regresia este o metodă foarte versatilă, fiind utilizată în studii longitudinale și de cohortă pentru a monitoriza schimbările de-a lungul timpului și pentru a evalua impactul diferiților factori în funcție de context. În educație, de exemplu, regresia poate fi utilizată pentru a evalua eficiența unei metode noi de predare și pentru a determina în ce măsură aceasta îmbunătățește performanța academică (Pituch & Stevens, 2015).

Un alt beneficiu al regresiei este acela că permite analiza influenței multiplelor variabile simultan, oferind o imagine completă a relațiilor complexe care pot exista între factorii de influență. Spre deosebire de corelație, care măsoară doar asocierea între două variabile, regresia permite o analiză multivariațională, care ia în considerare efectele combinate ale variabilelor independente. Acest lucru este extrem de util în cercetarea socială, unde fenomenele complexe sunt adesea influențate de mai mulți factori care interacționează între ei (Coetzee & Merwe, 2010).

Pentru studenți, înțelegerea și utilizarea corelațiilor și regresiei reprezintă o parte fundamentală a pregătirii lor în științele sociale și comportamentale. Aceste metode oferă bazele necesare pentru a interpreta datele într-un mod corect și pentru a formula concluzii bazate pe dovezi. De asemenea, ele oferă abilități esențiale pentru carierele lor viitoare, fie că este vorba de analiza efectelor unei intervenții în educație, de evaluarea

eficacității unei terapii în psihologie sau de măsurarea impactului unui program social (Lalonde & Gardner, 1993).

Pentru viitorii psihologi, sociologi și practicieni în asistență socială, formarea în corelații și regresii este esențială pentru a înțelege și interpreta corect studiile de cercetare din domeniul lor. Aceasta le permite să aplice metode riguroase pentru analiza datelor, oferindu-le capacitatea de a evalua impactul variabilelor și de a lua decizii informate în practica profesională. De asemenea, utilizarea acestor metode contribuie la dezvoltarea gândirii critice și a abilității de a interpreta rezultatele statistice în mod obiectiv, oferind astfel o bază solidă pentru cercetarea și practica aplicată.

În concluzie, atât analizele corelaționale, cât și cele de regresie sunt fundamentale pentru explorarea și înțelegerea relațiilor dintre variabile în științele sociale și comportamentale. Corelația oferă o imagine de ansamblu a asocierilor dintre variabile, în timp ce regresia oferă o înțelegere mai profundă a relațiilor cauzale, permițând construirea de modele predictive care pot ghida intervențiile și politicile. Aceste metode nu doar sprijină cercetarea și interpretarea datelor, ci și oferă un cadru pentru aplicarea informațiilor obținute în practică, contribuind la dezvoltarea unor soluții bazate pe dovezi și la îmbunătățirea calității vieții în diverse domenii.

Astfel, ghidul își propune să ajute studenții să își dezvolte o înțelegere solidă a acestor metode, oferindu-le instrumentele necesare pentru a explora, analiza și interpreta datele într-un mod riguros și informativ. Acest capitol oferă o bază teoretică pentru aplicarea corelațiilor și regresii în diverse contexte, pregătindu-i pe studenți pentru cercetări ulterioare și pentru practică profesională de succes în educație, psihologie și asistență socială.

1.3. Etapele procesului de analiză statistică și aplicații practice

Analiza statistică aplicată este un proces structurat, esențial pentru dezvoltarea cunoștințelor științifice și fundamentarea deciziilor bazate pe dovezi. Acest proces implică o serie de pași interdependenți, printre care se numără colectarea datelor, verificarea asumpțiilor, efectuarea analizei și interpretarea rezultatelor. La fiecare pas, precizia și rigurozitatea sunt critice pentru asigurarea validității și replicabilității concluziilor (Nisbet, Elder & Miner, 2009). În educație, psihologie și asistență socială, aplicarea practică a statisticii este fundamentală pentru evaluarea intervențiilor, identificarea

nevoilor specifice și optimizarea strategiilor de acțiune. Acest subcapitol descrie aplicațiile practice ale analizei statistice și etapele procesului, oferind o perspectivă practică asupra implementării acestor tehnici.

Primul pas în procesul de analiză statistică aplicată este colectarea datelor, care necesită o abordare sistematică și atent planificată. Fără date de calitate, întreaga analiză devine inutilă, iar concluziile rezultate pot fi eronate sau irelevante. În educație și psihologie, de exemplu, este important să se asigure că datele sunt colectate într-un mod standardizat și că variabilele relevante sunt definite și măsurate clar. Conform lui Sawyer (2005), acest proces presupune selectarea și controlul atent al variabilelor, pentru a reduce posibilitatea de erori de măsurare și a elimina influențele externe care pot distorsiona rezultatele. De asemenea, este crucial să se asigure că eșantionul este reprezentativ pentru populația țintă, deoarece acest lucru afectează în mod direct validitatea externă a studiului.

În asistența socială, colectarea datelor poate implica utilizarea de chestionare, interviuri, observații sau evaluări clinice. Acest proces trebuie să fie realizat cu etică și responsabilitate, având în vedere că mulți clienți sunt vulnerabili, iar confidențialitatea și dreptul la intimitate trebuie respectate. În educație, colectarea datelor poate presupune administrarea de teste, sondaje și observarea comportamentului elevilor, iar în psihologie, aceasta poate include o varietate de tehnici, de la teste de inteligență la inventare de personalitate. Colectarea riguroasă a datelor stabilește baza pentru o analiză corectă și semnificativă a fenomenelor complexe studiate.

Odată colectate, datele trebuie să fie evaluate în raport cu anumite asumții statistice. În analiza statistică aplicată, verificarea asumțiilor este esențială, deoarece metodele statistice se bazează adesea pe presupuneri legate de distribuția datelor, liniaritatea relațiilor dintre variabile, omogenitatea varianțelor și independența observațiilor. În cazul în care aceste asumții sunt încălcate, rezultatele analizei pot fi compromise, iar interpretarea concluziilor poate deveni eronată (Tinsley & Brown, 2000).

În educație, verificarea asumțiilor este importantă pentru asigurarea faptului că metodele alese sunt potrivite contextului specific. De exemplu, în analiza diferențelor de performanță între două grupuri de elevi, asumția de normalitate este esențială pentru aplicarea testelor t. În psihologie, asumția de liniaritate este esențială pentru interpretarea corectă a unei regresii liniare simple. De asemenea, în asistența socială, omogenitatea varianțelor poate

influența rezultatele unui test ANOVA aplicat pentru a evalua eficiența diferitelor tipuri de intervenții sociale.

Verificarea asumpțiilor este un pas important care precede analiza propriu-zisă. În cazul în care aceste asumpții nu sunt îndeplinite, se pot aplica metode statistice nonparametrice, care sunt mai flexibile și nu necesită asumpții stricte privind distribuția datelor. Alegerea corectă a metodelor statistice și verificarea adecvată a asumpțiilor asigură că analiza produce rezultate valide și replicabile, susținând astfel fundamentarea științifică a intervențiilor și concluziilor cercetării (Arlinghaus, 2020).

Odată ce asumpțiile au fost verificate și metodele selectate, urmează analiza efectivă a datelor. În funcție de scopul cercetării și de natura variabilelor implicate, cercetătorii pot folosi tehnici simple, cum ar fi media și abaterea standard, sau tehnici mai complexe, precum corelația și regresia, pentru a descoperi tiparele și relațiile dintre variabile. Analiza corelațională este adesea utilizată pentru a măsura asocierea dintre variabile, fără a presupune o relație cauzală. De exemplu, în educație, cercetătorii pot folosi corelația pentru a examina relația dintre participarea la ore și performanța academică, obținând astfel o măsură clară a legăturii dintre cele două variabile. În psihologie, corelația poate ajuta la identificarea relațiilor dintre trăsăturile de personalitate și nivelul de stres, oferind informații valoroase pentru intervențiile terapeutice.

Regresia, pe de altă parte, este utilizată pentru a estima relațiile cauzale și pentru a construi modele predictive. În educație, de exemplu, analiza de regresie poate fi utilizată pentru a evalua impactul variabilelor independente, cum ar fi metodele de predare și mediul familial, asupra performanței academice. În asistența socială, regresia poate ajuta la identificarea factorilor care contribuie la îmbunătățirea bunăstării emoționale a clienților, oferind informații esențiale pentru dezvoltarea unor programe de suport eficace (Racine, Su & Ullah, 2014). Această etapă de analiză oferă date critice pentru cercetători, permițându-le să construiască modele care explică fenomene complexe și să facă predicții relevante în context practic.

După ce analiza a fost efectuată, urmează interpretarea rezultatelor, o etapă esențială pentru extragerea concluziilor valabile și aplicabile. Interpretarea corectă a rezultatelor necesită cunoștințe avansate despre semnificația statistică și despre parametrii relevanți ai modelului aplicat.

Potrivit lui Tinsley & Brown (2000), interpretarea adecvată a rezultatelor permite cercetătorilor să evite concluziile nefondate și să ofere o înțelegere clară și concisă a implicațiilor descoperirilor lor. De exemplu, într-un studiu care examinează efectul unei noi metode de predare asupra performanței academice, interpretarea corectă a coeficienților de regresie poate indica dacă metoda este eficientă și dacă impactul său este semnificativ statistic.

Raportarea rezultatelor trebuie realizată într-un mod accesibil și transparent, mai ales în contextul studiilor din științele educației, psihologie și asistență socială. Conform lui Arlinghaus (2020), un raport statistic bine structurat nu doar prezintă rezultatele brute, ci oferă o interpretare profundă a implicațiilor acestora, facilitând astfel aplicabilitatea concluziilor în contexte reale. Raportarea corectă implică prezentarea rezultatelor statistice într-o manieră care permite replicarea studiului și evaluarea independenței variabilelor.

Pentru studenți și practicieni, raportarea este o etapă esențială a procesului de cercetare, deoarece permite transmiterea informațiilor într-un mod clar și consistent. În special în domenii precum asistența socială și educația, unde descoperirile cercetării sunt adesea utilizate pentru a fundamenta politici publice și intervenții, o raportare corectă este esențială pentru implementarea eficientă a recomandărilor.

Un aspect important al analizei statistice aplicate este integrarea rezultatelor în practică, pentru a sprijini luarea deciziilor informate. În educație, de exemplu, rezultatele statistice pot ghida dezvoltarea unor politici educaționale mai eficiente, bazate pe date empirice privind metodele de predare și implicarea elevilor. În psihologie, aplicabilitatea rezultatelor este esențială pentru îmbunătățirea intervențiilor clinice și pentru personalizarea tratamentelor în funcție de nevoile specifice ale clienților (Sawyer, 2005). În asistența socială, interpretarea și aplicarea rezultatelor ajută la crearea unor programe de suport mai adaptate nevoilor beneficiarilor și la evaluarea eficienței acestora în mod continuu.

La finalul acestui capitol introductiv, ne-am familiarizat cu importanța analizei statistice aplicate în științele educației, psihologie și asistență socială. Am discutat despre rolul esențial al statisticii în înțelegerea și interpretarea relațiilor dintre variabile, precum și despre scopurile și obiectivele analizelor corelaționale și de regresie. În capitolele următoare, vom parcurge pas cu pas fiecare metodă și tehnică statistică, aprofundând cunoștințele necesare

pentru a le aplica corect și a obține concluzii solide. Astfel, Capitolul 2 va oferi o introducere detaliată în fundamentele analizei corelaționale, explorând tipurile de corelații (Pearson, Spearman, Kendall și corelații parțiale), metodele de calcul și interpretare a coeficienților, dar și limitările și erorile comune care pot apărea în interpretarea corelațiilor. Capitolul 3 va aborda regresia liniară simplă, explicând conceptele fundamentale și asumțiile acestei metode, precum și interpretarea coeficienților de regresie și utilizarea regresiei pentru predicția rezultatelor și verificarea modelului.

Capitolul 4 va extinde discuția către modelele de regresie mai complexe, inclusiv regresia liniară multiplă și modelele non-liniare (de tip pătratic sau curbiliniu), cu accent pe construcția și interpretarea acestor modele, testarea asumțiilor și optimizarea lor. În Capitolul 5, vom explora conceptul de mediere, analizând diferite tipuri de mediere (simplă, paralelă, secvențială) și modul de interpretare a efectelor indirecte. Următorul, Capitolul 6, se va concentra pe medierea moderată, incluzând definirea și aplicarea acesteia, identificarea interacțiunilor dintre variabile și implicațiile în cercetarea socială.

Pentru a asigura o aplicare corectă și eficientă a acestor metode, Capitolul 7 va prezenta instrumentele și software-urile principale utilizate în analiza statistică, precum SPSS, JASP și JAMOVI, oferind tutoriale și ghiduri practice pentru fiecare. În final, Capitolul 8 va aborda interpretarea și prezentarea rezultatelor statistice, oferind recomandări despre cum să organizăm un raport statistic conform standardelor APA, să formulăm concluzii riguroase și să utilizăm rezultatele în contextul cercetării. Astfel, ghidul își propune să devină o resursă completă și aplicativă pentru studenți și cercetători, facilitând o înțelegere profundă și riguroasă a metodelor statistice esențiale.

CAPITOLUL 2.

Fundamentele analizei corelaționale

Analiza corelațională este una dintre cele mai utilizate metode statistice în cercetarea socială și comportamentală, fiind esențială pentru investigarea relațiilor dintre variabile. Corelațiile oferă o măsură a asocierii între variabile, fără a implica neapărat o relație cauzală, permițând cercetătorilor să identifice tipare și asocieri care pot fi explorate ulterior prin alte metode statistice. Acest capitol explorează fundamentele analizei corelaționale, prezentând principalele tipuri de corelații utilizate în cercetare, metodele de calcul și interpretarea coeficienților de corelație, precum și limitările și erorile comune asociate interpretării corelațiilor.

Corelația poate fi măsurată printr-o varietate de metode, fiecare având specificul său în funcție de tipul de date și de natura relației dintre variabile. Cele mai utilizate tipuri de corelație sunt coeficientul de corelație Pearson, Spearman și Kendall, fiecare dintre acestea având avantaje și limitări.

Coeficientul de corelație Pearson este unul dintre cei mai cunoscuți și folosiți indicatori ai relației liniare între două variabile continue (Bishara & Hittner, 2012). Acesta măsoară gradul de asociere liniară între variabile, indicând dacă o creștere într-o variabilă corespunde unei creșteri sau scăderi în cealaltă variabilă. Coeficientul Pearson este sensibil la distribuția datelor, fiind adecvat doar pentru datele normale și relațiile liniare. Când aceste asumptii sunt îndeplinite, Pearson oferă o măsură clară și interpretabilă a intensității relației dintre variabile.

Conform lui Miot (2018), coeficientul Pearson este de obicei folosit în studii clinice și experimentale pentru a evalua relațiile dintre variabile fiziologice și comportamentale, dar utilizarea sa este limitată în situațiile în care datele nu sunt distribuite normal sau relația dintre variabile nu este liniară. În astfel de cazuri, coeficientul Spearman sau Kendall poate oferi o măsură mai potrivită a asocierii.

Coeficientul Spearman este o măsură a corelației bazată pe ranguri, fiind utilizat frecvent atunci când datele nu îndeplinesc asumțiile necesare pentru aplicarea coeficientului Pearson. Spearman este adesea folosit pentru a măsura asocierea dintre variabile ordinale sau pentru variabile continue care nu prezintă o relație liniară clară (Puth, Neuhäuser & Ruxton, 2015). Spre deosebire de coeficientul Pearson, Spearman nu necesită ca datele să fie distribuite normal, făcându-l util în analiza unor variabile neconvenționale.

Studiul lui Rosa și colaboratorii (2022) ilustrează aplicabilitatea coeficientului Spearman în domeniul analizei multiomice pentru predicția pierderii în greutate, demonstrând că acesta poate identifica asocieri între predictorii biologici și rezultatele clinice. Totodată, Spearman este folosit în studiile psihologice pentru a corela scoruri non-normale, cum ar fi evaluările de simptomatologie psihiatrică (Arndt, Turvey & Andreasen, 1999).

Coeficientul de corelație Kendall, cunoscut și sub denumirea de coeficientul τ (tau) al lui Kendall, este o altă metodă nonparametrică de măsurare a asocierii dintre variabile. Kendall este mai robust la distribuții non-normale și este adesea folosit pentru evaluarea asocierilor în seturi de date mici sau în situațiile în care datele prezintă multe legături (Fredricks & Nelsen, 2007). În comparație cu Spearman, coeficientul Kendall este mai sensibil la variațiile în structura de ordine a datelor, oferind o măsură mai precisă a corelației în cazurile în care legăturile între variabile sunt complexe.

Studiul lui Williams (1986) arată că coeficientul Kendall este deosebit de eficient în geografie și științele pământului, unde datele nu sunt adesea distribuite normal și relațiile dintre variabile sunt adesea complexe și influențate de multiple condiții externe. În cercetările comportamentale și psihologice, coeficientul Kendall este folosit pentru a evalua relații între variabile care au structuri de date specifice, oferind o alternativă robustă la coeficientul Spearman în analiza relațiilor dintre scorurile de rang.

Corelațiile parțiale reprezintă o extensie a corelațiilor clasice, permițând controlul influenței unei variabile terțe asupra relației dintre alte două variabile. Această metodă este utilă în studii complexe unde sunt implicate mai multe variabile, ajutând cercetătorii să izoleze relațiile de interes prin eliminarea efectului variabilelor de control (Kendall, 1942). Conform lui Gripenberg (1992), corelațiile parțiale sunt esențiale în studiile care implică seturi de date extinse și multiple variabile, fiind aplicate pentru

a obține măsuri precise ale relației dintre variabile independente de influențele exterioare.

Studiul lui Moran (1951) descrie corelația parțială ca un instrument util în analiza variabilelor multiple, în special în domenii precum economia și sociologia, unde influența covariatelor trebuie eliminată pentru a înțelege corelațiile directe. În mod similar, Macklin (1982) subliniază importanța corelațiilor parțiale în cercetările astronomice, demonstrând cum acestea pot fi utilizate pentru a controla variabilele de fond în analiza relațiilor dintre sursele radio și proprietățile lor fizice.

2.1. Tipuri de corelații: Pearson, Spearman, Kendall și corelații parțiale

Corelația măsoară gradul de asociere dintre două variabile, oferind cercetătorilor posibilitatea de a identifica tipare și relații între fenomene complexe. Cele mai utilizate tipuri de corelații sunt coeficienții Pearson, Spearman și Kendall, fiecare potrivit în funcție de tipul de date și de natura relației dintre variabile. În plus, corelațiile parțiale permit controlul influenței variabilelor terțe, izolând relațiile de interes și permițând o analiză mai detaliată.

Coeficientul de corelație Pearson

Coeficientul de corelație Pearson (r) este cea mai frecvent utilizată măsură pentru evaluarea relațiilor liniare între două variabile continue. Acesta este definit ca raportul dintre covarianța celor două variabile și produsul deviațiilor standard ale acestora. Formula pentru coeficientul Pearson este:

$$r = \frac{\sum(X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum(X - \bar{X})^2 \sum(Y - \bar{Y})^2}}$$

unde X și Y sunt variabilele de interes, iar \bar{X} și \bar{Y} sunt mediile aritmetice ale acestora. Coeficientul r ia valori între -1 și 1, unde valorile apropiate de ± 1 indică o relație puternică, iar valorile apropiate de 0 sugerează o relație slabă sau inexistentă. Un r pozitiv indică o corelație directă (pe măsură ce X crește,

Y crește), în timp ce un r negativ sugerează o relație inversă (pe măsură ce X crește, Y scade).

Coeficientul Pearson este ideal pentru datele distribuite normal și relațiile liniare, fiind folosit frecvent în educație pentru a examina asocieri între variabile cum ar fi nivelul de educație și performanța școlară. De exemplu, în evaluarea relației dintre timpul de studiu și performanțele academice, un coeficient Pearson ridicat ar indica faptul că timpul investit în studiu este direct proporțional cu performanțele obținute la examene. În psihologie, Pearson este utilizat pentru a explora relații între variabile continue, cum ar fi intensitatea emoțională și nivelul de anxietate.

Cu toate acestea, coeficientul Pearson este limitat la relațiile liniare și este sensibil la valorile extreme (outlieri). Atunci când datele nu sunt distribuite normal sau relația dintre variabile nu este liniară, coeficientul Spearman sau Kendall poate oferi o măsură mai potrivită a asocierii.

Coeficientul de Corelație Spearman

Coeficientul de corelație Spearman (ρ sau r_s) este o măsură nonparametrică a asocierii, utilizată frecvent atunci când datele nu îndeplinesc asumțiile necesare pentru aplicarea coeficientului Pearson. Coeficientul Spearman este calculat pe baza rangurilor variabilelor, și nu pe valorile brute, fiind astfel mai puțin sensibil la outlieri și adecvat pentru variabile ordinale sau continue care nu prezintă o relație liniară clară.

Formula coeficientului Spearman pentru două variabile ordonate X și Y este:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

unde d_i reprezintă diferența dintre rangurile corespunzătoare ale fiecărei perechi de valori, iar n este numărul de observații. Coeficientul Spearman variază între -1 și 1, cu interpretări similare coeficientului Pearson: o valoare de 1 indică o corelație perfect pozitivă, -1 o corelație perfect negativă, iar 0 indică absența unei corelații.

Spearman este ideal pentru studiile din asistență socială și psihologie, unde datele sunt adesea ordinale sau nu urmează o distribuție normală. De exemplu, Spearman poate fi utilizat pentru a examina relația dintre nivelul de stres și satisfacția profesională, unde datele sunt adesea colectate pe scale ordinale (ex. de la „foarte nesatisfăcut” la „foarte satisfăcut”). În educație, coeficientul Spearman este utilizat pentru a evalua asocieri între factorii psihosociali și performanțele școlare, unde măsurătorile nu sunt întotdeauna distribuite normal (Puth, Neuhäuser & Ruxton, 2015).

Studiul lui Rosa et al. (2022) a aplicat coeficientul Spearman în analiza multiomică pentru a identifica predictorii ai pierderii în greutate, demonstrând astfel aplicabilitatea acestuia în domenii complexe unde variabilele sunt eterogene și nu respectă distribuții normale.

Coeficientul de Corelație Kendall

Coeficientul de corelație Kendall (τ), cunoscut și sub denumirea de coeficientul tau al lui Kendall, este o altă măsură nonparametrică de evaluare a asocierii dintre variabile ordinale. Acesta se bazează pe concordanța și discordanța perechilor de valori și este deosebit de eficient în seturi de date mici sau atunci când există multe legături (valori egale). Formula pentru coeficientul Kendall este:

$$\tau = \frac{(C - D)}{\frac{n(n-1)}{2}}$$

unde C este numărul de perechi concordante, D este numărul de perechi discordante, iar n reprezintă numărul de observații. Un avantaj al coeficientului Kendall este că oferă o măsură a corelației mai precisă atunci când datele sunt puțin distribuite sau conțin legături multiple.

Coeficientul Kendall este frecvent utilizat în psihologie și educație, unde datele sunt clasate și relațiile pot fi influențate de diverși factori externi. De exemplu, în studiile privind satisfacția elevilor față de metodele de predare, coeficientul Kendall poate fi utilizat pentru a analiza relația dintre diferite strategii didactice și nivelul de implicare al elevilor. În psihologie, Kendall este util pentru a corela variabile de tip rang, cum ar fi ordinea

preferințelor personale sau evaluările de personalitate în contexte de consiliere (Fredricks & Nelsen, 2007).

Corelațiile parțiale

Corelațiile parțiale reprezintă o extensie a corelațiilor clasice, permițând controlul influenței unei variabile terțe asupra relației dintre alte două variabile. Aceasta este o tehnică esențială în studiile unde mai multe variabile pot interacționa, permițând cercetătorilor să izoleze relațiile de interes și să elimine efectele confuzionale. Formula pentru corelația parțială între două variabile X și Y , controlând pentru o a treia variabilă Z , este:

$$r_{XY.Z} = \frac{r_{XY} - r_{XZ} \cdot r_{YZ}}{\sqrt{(1 - r_{XZ}^2)(1 - r_{YZ}^2)}}$$

unde r_{XY} este coeficientul de corelație între X și Y , r_{XZ} între X și Z , iar r_{YZ} între Y și Z . Corelațiile parțiale sunt utile în analize complexe, cum ar fi evaluarea influenței mediului familial asupra performanței academice, controlând pentru efectul altor factori cum ar fi venitul familial.

În educație, corelațiile parțiale pot fi utilizate pentru a examina relația dintre implicarea părinților în educația copiilor și performanțele academice, eliminând influențele sociale sau economice. În psihologie, corelațiile parțiale sunt adesea utilizate pentru a studia legăturile între trăsăturile de personalitate și comportamentele specifice, controlând pentru influențele mediului, cum ar fi suportul social (Gripenberg, 1992).

Studiul lui Moran (1951) și al lui Macklin (1982) sugerează că utilizarea corelațiilor parțiale este esențială în contextul analizelor cu multiple variabile, permițând o înțelegere mai profundă a relațiilor directe dintre variabile prin eliminarea influenței confuzionale a variabilelor de fond.

2.2. Calcularea și interpretarea coeficienților de corelație

Calcularea și interpretarea coeficienților de corelație constituie un element central în analiza corelațională, oferind o măsură numerică a intensității și direcției relației dintre variabile. Coeficientul de corelație

Pearson, utilizat pentru variabile distribuite normal și pentru relații liniare, este adecvat pentru seturile de date parametrice. Coeficienții Spearman și Kendall, în schimb, sunt metode nonparametrice, folosite pentru seturi de date care nu respectă distribuția normală. Spearman și Kendall sunt adecvați în special pentru date ordinale, unde rangurile variabilelor sunt mai relevante decât valorile lor absolute (Obilor & Amadi, 2018).

Coeficientul de corelație Pearson (r) măsoară asocierea liniară între două variabile continue, iar valorile sale variază între -1 și 1, unde valorile apropiate de -1 sau 1 indică o asociere puternică (pozitivă sau negativă), iar valorile apropiate de 0 indică o asociere slabă sau inexistentă (Obilor & Amadi, 2018). Interpretarea lui r necesită atenție, deoarece valoarea poate fi influențată de distribuția datelor și de prezența outlierilor. Coeficientul de corelație Pearson este util în studiile în care cercetătorii doresc să investigheze dacă o variabilă continuă poate prezice o altă variabilă continuă. De exemplu, în educație, coeficientul Pearson poate fi folosit pentru a analiza corelația între numărul de ore de studiu și rezultatele la examene, presupunând că ambele variabile sunt continue și distribuite normal.

Coeficientul Spearman (ρ) se bazează pe ranguri și este potrivit pentru variabile ordinale sau continue fără o relație liniară clară. Spre deosebire de Pearson, Spearman nu necesită ca datele să fie distribuite normal și este mai puțin sensibil la valori extreme (Iki, Sato & Tomizawa, 2018). Formula Spearman ia în considerare diferențele între rangurile fiecărei perechi de valori, ceea ce îl face util în analiza seturilor de date clasate. În interpretarea coeficientului Spearman, valorile de ± 0.3 indică o corelație slabă, ± 0.5 o corelație moderată, iar valori mai mari de ± 0.7 o corelație puternică (Lu et al., 2018). Coeficientul Spearman transformă valorile brute în ranguri, calculând corelația dintre ranguri în locul valorilor brute. Acesta este ideal pentru situațiile în care relația dintre variabile este monotonică (adică una crește sau scade în mod constant în raport cu cealaltă), dar nu neapărat liniară. De exemplu, în psihologie, Spearman poate fi utilizat pentru a evalua relația dintre scorurile de satisfacție la locul de muncă și nivelul de stres raportat de angajați, datele fiind adesea ordinale.

Coeficientul de corelație Kendall (τ) este similar lui Spearman în utilizarea rangurilor, însă este mai precis în cazurile în care există legături multiple între valorile variabilelor. Coeficientul Kendall este ideal pentru

datele clasate și pentru seturi de date mici, unde relațiile dintre variabile sunt mai complexe (Fredricks & Nelsen, 2007). Studiile lui Williams (1986) confirmă că Kendall este preferabil Spearman în condiții de date clasate complexe, oferind o măsură robustă a relației. Kendall este adesea preferat pentru seturile de date mai mici sau pentru situațiile în care există multe legături între valorile variabilelor. De exemplu, în asistența socială, Kendall poate fi folosit pentru a analiza relația între gradul de satisfacție al clienților cu privire la serviciile primite și nivelul de implicare al acestora, datele fiind adesea clasate.

Interpretarea corelațiilor parțiale este, de asemenea, esențială pentru a înțelege relațiile directe între variabile, prin ajustarea pentru variabile de control. Corelațiile parțiale permit identificarea asocierilor autentice între variabile, eliminând influențele nedorite (Liu et al., 2018). Această tehnică este foarte utilă în domenii complexe precum studiile multiomice, unde interpretarea corectă a corelațiilor poate dezvălui relații ascunse importante (Rosa et al., 2022). Corelațiile parțiale sunt esențiale în studii multidimensionale, unde sunt necesare variabile de control pentru a izola relațiile de interes. De exemplu, în psihologie, dacă un cercetător dorește să investigheze relația dintre stima de sine și performanța academică, dar suspectează că influența sprijinului social ar putea afecta rezultatele, o corelație parțială permite controlul sprijinului social pentru a vedea dacă stima de sine influențează direct performanța academică.

Interpretarea corelațiilor parțiale este similară cu interpretarea corelațiilor simple, dar cu atenție sporită la influența variabilelor de control. Coeficientul rezultat indică doar relația dintre cele două variabile de interes, excluzând efectul variabilei de control. Liu și colaboratorii (2018) au subliniat că interpretarea corelațiilor parțiale oferă o măsură clară a relației directe între variabile, fiind extrem de utilă în studiile de mare complexitate, cum ar fi analizele multiomice sau studiile epidemiologice, unde există multiple variabile interconectate.

În practică, corelațiile parțiale sunt des utilizate în cercetarea educațională pentru a izola efectele unor factori socio-economici asupra performanțelor academice, controlând pentru alte influențe cum ar fi nivelul de educație al părinților. De asemenea, în asistența socială, corelațiile parțiale pot fi folosite pentru a înțelege mai bine cum diverse intervenții influențează

bunăstarea psihologică a clienților, eliminând influențele externe cum ar fi suportul familial.

2.3. Limitări și erori comune în interpretarea corelațiilor

Deși corelațiile sunt instrumente statistice fundamentale și de o mare valoare în cercetare, ele vin cu o serie de limitări care pot conduce la erori de interpretare, mai ales atunci când utilizarea și interpretarea acestora nu sunt realizate corespunzător. Printre cele mai frecvente probleme se numără interpretarea greșită a corelației ca relație cauzală, influența outlier-ilor, utilizarea inadecvată a coeficienților de corelație în contextul unor asumții statistice nerespectate și limitările impuse de dimensiunea eșantionului. Fiecare dintre aceste limitări impune o cunoaștere aprofundată a principiilor statistice pentru a evita interpretările eronate și pentru a obține rezultate valide.

Una dintre cele mai comune erori în interpretarea corelațiilor este asumarea unei relații cauzale pe baza unei asocieri observate. Coeficientul de corelație măsoară doar gradul de asociere între două variabile, dar nu oferă informații despre direcția influenței. Așadar, dacă două variabile sunt corelate, aceasta nu înseamnă că una dintre ele este cauza celeilalte. Această eroare de interpretare este frecventă în studiile observaționale, unde variabilele sunt măsurate simultan, dar nu sunt manipulate experimental.

Un exemplu clasic de eroare de cauzalitate este observația că există o corelație pozitivă între consumul de înghețată și numărul de înecuri. Aceasta nu înseamnă că consumul de înghețată provoacă înecuri; ambele variabile sunt influențate de un al treilea factor, temperatura, care crește în timpul verii și duce atât la consum mai ridicat de înghețată, cât și la o frecvență mai mare a înecurilor. În acest caz, variabila „temperatură” este un factor de confuzie, care explică corelația observată.

Aceasta este o limitare inerentă a corelațiilor și este esențial ca cercetătorii să fie precauți în a sugera cauzalitate pe baza corelației, mai ales în studiile de tip transversal sau observațional, unde relațiile cauzale nu pot fi stabilite direct.

Outlierii, sau valorile extreme, reprezintă observații care se îndepărtează semnificativ de celelalte valori din setul de date și pot distorsiona coeficientul de corelație. De exemplu, în cazul coeficientului

Pearson, care este sensibil la valorile extreme, prezența unui outlier poate conduce la supraestimarea sau subestimarea corelației între variabile. Aceasta este o problemă deoarece coeficientul Pearson este calculat pe baza mediei și a deviației standard, ambele fiind puternic influențate de valori extreme.

Există mai multe metode pentru a identifica outlierii, cum ar fi utilizarea scorurilor Z (valori mai mari de ± 3 sunt adesea considerate outlieri), analiza grafică prin diagrame de tip boxplot sau histograme și utilizarea regulii intervalului intercuartilic (IQR).

După identificarea outlierilor, cercetătorii trebuie să decidă dacă aceștia trebuie păstrați, eliminați sau înlocuiți, în funcție de natura datelor și de ipotezele studiului. Spre exemplu, în cazul în care un outlier este rezultatul unei erori de măsurare, acesta poate fi eliminat; însă, dacă valoarea extremă reprezintă un fenomen natural sau relevant, eliminarea sa ar putea duce la pierderea unor informații importante.

Pentru coeficienții de corelație nonparametrici, cum ar fi Spearman și Kendall, outlierii au un impact mai redus, deoarece aceste coeficienți se bazează pe ranguri și nu pe valorile brute ale variabilelor (Puth, Neuhäuser & Ruxton, 2015).

Utilizarea incorectă a coeficienților de corelație în contextul unor asumții statistice nerespectate poate duce la interpretări greșite. Coeficientul de corelație Pearson, de exemplu, este adecvat doar pentru datele distribuite normal și pentru relațiile liniare. Când datele nu îndeplinesc aceste asumții, aplicarea coeficientului Pearson poate duce la estimări inexacte ale gradului de asociere dintre variabile (Bishara & Hittner, 2012).

Coeficienții de corelație nonparametrici, cum ar fi Spearman și Kendall, sunt mai adecvați în situațiile în care datele nu sunt distribuite normal sau relația dintre variabile nu este liniară. Coeficientul Spearman se bazează pe ranguri și este potrivit pentru date ordinale sau pentru variabile continue cu relații monotone. Coeficientul Kendall este similar, dar oferă o măsură mai robustă în prezența valorilor legate și este preferat pentru seturi de date mici sau cu multe legături (Williams, 1986).

Aceste alternative sunt valoroase în cercetare, deoarece reduc riscul interpretării greșite a corelațiilor în condițiile în care asumțiile Pearson nu sunt îndeplinite.

Dimensiunea eșantionului joacă un rol crucial în interpretarea corelațiilor, deoarece un eșantion mic poate limita puterea statistică a testului de corelație, afectând astfel validitatea rezultatelor. Cu cât eșantionul este mai mic, cu atât este mai dificil să se detecteze corelațiile semnificative, iar coeficientul de corelație poate fi instabil și susceptibil la fluctuații mari.

Pentru a asigura interpretări corecte, este recomandat să se efectueze teste de semnificație pentru coeficientul de corelație și să se raporteze intervalele de încredere. Intervalele de încredere oferă o estimare a varianței coeficientului de corelație și pot arăta dacă o corelație observată este robustă sau dacă rezultatul este doar un efect al dimensiunii mici a eșantionului.

În cazul corelațiilor parțiale, efectul dimensiunii eșantionului devine și mai evident, deoarece eliminarea efectelor unei covariate necesită o putere statistică suplimentară. O dimensiune redusă a eșantionului poate face ca estimările corelațiilor parțiale să fie instabile, conducând la rezultate inconsistente sau nesemnificative (Shi & Conrad, 2009). Prin urmare, este esențial ca cercetătorii să aibă eșantioane suficient de mari pentru a obține estimări fiabile și semnificative ale corelațiilor.

Corelațiile parțiale sunt utilizate pentru a controla efectul unei variabile de fundal și pentru a izola relația dintre alte două variabile. Cu toate acestea, interpretarea corelațiilor parțiale trebuie făcută cu precauție, deoarece prezența unei covariate poate masca sau exagera relația dintre variabilele de interes. De exemplu, controlarea unei variabile de fundal poate duce la obținerea unei corelații artificiale sau la subestimarea efectului real dintre variabilele analizate.

Un mod de a aborda această limitare este de a utiliza intervalele de încredere pentru corelațiile parțiale, o metodă propusă de Gripengberg (1992). Intervalele de încredere permit cercetătorilor să evalueze precizia estimării corelației parțiale și să evite concluziile pripite. În plus, utilizarea corelațiilor parțiale este mai adecvată atunci când există o justificare teoretică puternică pentru controlarea unei variabile de fundal, iar cercetătorii ar trebui să evite utilizarea excesivă a acestora în absența unei astfel de justificări.

Coliniaritatea apare atunci când două sau mai multe variabile independente sunt foarte corelate între ele, ceea ce poate distorsiona interpretarea rezultatelor. Multicoliniaritatea, o extensie a coliniarității, apare atunci când mai multe variabile independente sunt corelate într-o analiză de regresie multiplă. Aceasta poate face dificilă identificarea

contribuției individuale a fiecărei variabile și poate duce la coeficienți de corelație instabili și greu de interpretat.

Coliniaritatea și multicoliniaritatea sunt relevante în analiza corelațională, mai ales în studiile care implică mai multe variabile explicative. În astfel de cazuri, este recomandat să se utilizeze tehnici de reducere a coliniarității, cum ar fi eliminarea variabilelor redundante sau utilizarea analizelor factoriale pentru a crea variabile compozite.

În concluzie, analiza corelațională este un instrument statistic valoros, dar aplicarea sa corectă necesită o înțelegere aprofundată a limitărilor și a potențialelor erori de interpretare. Limitările corelației includ asumarea unei relații cauzale, influența valorilor extreme, aplicarea incorectă a coeficienților de corelație, impactul dimensiunii eșantionului și dificultățile în interpretarea corelațiilor parțiale și a celor în prezența coliniarității. Cercetătorii trebuie să utilizeze cu precauție coeficienții de corelație și să fie atenți la interpretarea acestora, având în vedere potențialele erori și limitări. Astfel, se poate asigura o evaluare riguroasă și fundamentată a asocierilor dintre variabile, contribuind la rezultate de înaltă calitate în studiul fenomenelor sociale și comportamentale.

CAPITOLUL 3.

Modele de regresie liniară simplă

Regresia liniară simplă este o metodă de analiză statistică esențială, utilizată pentru a examina și cuantifica relația dintre o variabilă dependentă (de răspuns) și o variabilă independentă (predictor). Această tehnică se bazează pe construirea unei ecuații liniare care descrie cum valoarea variabilei dependente se schimbă în funcție de modificările variabilei independente. Modelul de regresie liniară simplă are o aplicabilitate largă, fiind utilizat în diverse domenii precum științele sociale, psihologie, educație, economie și multe altele, datorită capacității sale de a estima tendințele și de a prezice valori viitoare pe baza datelor existente.

În cercetarea științifică, regresia liniară simplă este o metodă fundamentală deoarece permite identificarea și cuantificarea relațiilor între variabile. Utilizarea acesteia facilitează înțelegerea dacă și în ce măsură o schimbare a variabilei independente X se asociază cu o modificare a variabilei dependente Y . De exemplu, în psihologie, un cercetător ar putea utiliza regresia liniară simplă pentru a determina relația dintre nivelul de stres și performanța academică. În acest caz, modelul ar putea furniza informații despre cum fiecare unitate de creștere în stres se corelează cu o schimbare în performanța academică.

Regresia liniară simplă are o aplicație deosebită și în previziuni. Odată ce modelul de regresie este stabilit și coeficienții sunt estimați, acesta poate fi utilizat pentru a face predicții despre variabila dependentă pentru noi valori ale variabilei independente. Capacitatea de predicție este esențială în domenii ca economia sau epidemiologia, unde se dorește anticiparea unor rezultate precum evoluția prețurilor sau incidența unor afecțiuni pe baza factorilor de risc observați.

3.1. Concepte fundamentale și asumțiile regresiei liniare simple

Regresia liniară simplă se bazează pe modelul matematic:

$$Y = \beta_0 + \beta_1 X + \epsilon$$

unde Y reprezintă variabila dependentă, X este variabila independentă, β_0 este interceptul (sau ordonata la origine), β_1 este panta (coeficientul de regresie), iar ϵ este eroarea reziduală (Zou, Tuncali & Silverman, 2003). Acest model presupune o relație liniară între X și Y , astfel încât o unitate de creștere a lui X va produce o modificare constantă în Y , determinată de coeficientul β_1 (Maulud & Abdulazeez, 2020).

Pentru ca modelul de regresie liniară simplă să fie valid și interpretările rezultate să fie corecte, este necesar să fie respectate o serie de asumții esențiale. Prima asumție fundamentală este liniaritatea, care presupune că relația dintre variabila independentă și cea dependentă poate fi reprezentată sub forma unei linii drepte. Cu alte cuvinte, schimbările în variabila dependentă Y ar trebui să fie proporționale cu schimbările în variabila independentă X , ceea ce înseamnă că orice modificare în X este însoțită de o modificare constantă în Y (James et al., 2023). Această proprietate poate fi verificată prin reprezentări grafice, cum ar fi un scatter plot între X și Y ; dacă datele formează o formă liniară, putem presupune că asumția este îndeplinită. De exemplu, în psihologie, s-ar putea analiza relația liniară dintre nivelul de anxietate și performanța la examene, unde o creștere în anxietate ar putea corespunde unei scăderi proporționale în performanță.

A doua asumție este independența observațiilor, care necesită ca fiecare observație din setul de date să fie independentă de celelalte. Aceasta înseamnă că valoarea unei observații nu ar trebui să influențeze valoarea altor observații, lucru esențial pentru a evita erori sistematice și pentru a asigura corectitudinea estimării coeficienților (Bangdiwala, 2018). În absența independenței, rezultatele modelului pot deveni distorsionate. De exemplu, dacă sunt analizate scorurile la un test de performanță ale studenților din mai multe clase, ar trebui să ne asigurăm că fiecare scor este independent de celelalte, altfel, relațiile observate ar putea fi afectate de factori comuni între clase (precum profesorul sau mediul de învățare), care creează corelații false între scoruri.

Homoscedasticitatea reprezintă o altă asumptie esențială în regresia liniară simplă și se referă la faptul că varianța rezidualelor trebuie să fie constantă pe întreaga gamă a valorilor variabilei independente. Mai precis, magnitudinea erorilor sau a diferențelor dintre valorile prezise și cele observate nu ar trebui să depindă de valorile variabilei independente (Marill, 2004). Dacă această asumptie este încălcată și varianța erorilor crește sau scade sistematic pe măsură ce X variază, modelul prezintă ceea ce se numește heteroscedasticitate. În practică, heteroscedasticitatea poate fi întâlnită în domeniul educației, unde, de exemplu, relația dintre timpul de studiu și performanța la teste ar putea prezenta o variabilitate diferită la extreme: studenții care studiază foarte puțin sau foarte mult pot avea performanțe extrem de variabile. Heteroscedasticitatea poate fi verificată grafic printr-un plot al rezidualelor față de valorile prezise; dacă reziduurile nu sunt distribuite uniform în jurul liniei zero, această asumptie este probabil încălcată.

Ultima asumptie majoră este normalitatea rezidualelor. Reziduurile (diferențele între valorile observate și cele estimate de model) trebuie să fie distribuite normal pentru a permite interpretarea semnificației statistice a coeficienților de regresie și pentru a construi intervale de încredere precise (Hope, 2020). Dacă reziduurile nu sunt distribuite normal, estimările coeficienților de regresie pot fi inexacte, iar rezultatele inferențiale (cum ar fi testele de semnificație) pot să nu fie valabile. Această asumptie poate fi evaluată prin histogramă sau printr-un grafic Q-Q (quantile-quantile), unde o deviere semnificativă de la linia de normalitate sugerează că această asumptie nu este îndeplinită. De exemplu, în asistența socială, atunci când se analizează efectul numărului de ședințe de consiliere asupra gradului de satisfacție a beneficiarilor, normalitatea rezidualelor ar trebui să fie verificată pentru a asigura că modelele folosite produc rezultate stabile și valide.

Nerespectarea acestor asumptii poate duce la erori semnificative în interpretarea rezultatelor și la concluzii înșelătoare. Dacă, de exemplu, reziduurile nu sunt distribuite normal, coeficienții de regresie calculați pot deveni instabili, ceea ce înseamnă că pot fluctua considerabil la modificarea ușoară a datelor. Acest lucru face ca interpretarea semnificației statistice să fie nesigură (Krieger, Pollak & Yakir, 2003).

3.2. Interpretarea coeficienților de regresie și semnificația acestora

Coeficienții de regresie într-un model liniar simplu, denotați prin β_0 și β_1 , sunt valorile numerice care definesc linia de regresie și, implicit, relația dintre variabila independentă X și variabila dependentă Y . Acești coeficienți au roluri și interpretări distincte în contextul modelului de regresie, oferind informații cruciale despre dinamica dintre variabile.

Interceptul (β_0), sau ordonata la origine, reprezintă valoarea estimată a variabilei dependente Y atunci când variabila independentă X are valoarea zero. Matematic, β_0 poate fi interpretat ca punctul de intersecție al liniei de regresie cu axa Y . În unele cazuri, interpretarea acestuia poate fi dificilă sau chiar lipsită de semnificație practică, mai ales atunci când valoarea zero a lui X nu are o relevanță specifică în contextul cercetării (Sedgwick, 2013). Totuși, în situațiile în care $X=0$ este semnificativ, cum ar fi în măsurarea efectului unui tratament sau a impactului unei intervenții în punctul de referință zero, interpretarea interceptului devine relevantă.

De exemplu, într-un studiu de educație în care se analizează impactul numărului de ore de studiu (X) asupra scorurilor la un test (Y), interceptul β_0 ar reprezenta scorul mediu pe care l-ar obține studenții care nu au studiat deloc. Dacă acest intercept este, să zicem, 50, înseamnă că, în absența studiului, se așteaptă ca un student să obțină un scor de 50. Totuși, această interpretare trebuie abordată cu prudență, mai ales dacă setul de date nu include valori ale lui X apropiate de zero, caz în care extrapolarea ar putea să nu fie validă.

Coeficientul de pantă (β_1) descrie rata de schimbare a variabilei Y pentru fiecare unitate de creștere a variabilei X . Acest coeficient este esențial în determinarea naturii relației dintre variabilele analizate: dacă β_1 este pozitiv, atunci Y crește pe măsură ce X crește, ceea ce indică o relație directă între variabile; dacă β_1 este negativ, Y scade atunci când X crește, sugerând o relație inversă (Andersen & Skovgaard, 2010).

Interpretarea lui β_1 depinde de unitățile de măsură ale variabilelor implicate și de contextul specific al studiului. De exemplu, în psihologie, β_1 poate reprezenta măsura în care o variabilă psihologică, cum ar fi nivelul de stres (variabila independentă X), influențează performanța academică (variabila dependentă Y). Dacă $\beta_1 = -0.5$, acest lucru sugerează că pentru fiecare unitate de creștere a stresului, performanța academică scade, în medie, cu 0.5 unități. În asistența socială, un exemplu similar ar putea

implica analiza efectului numărului de ședințe de consiliere (X) asupra stării de bine a clienților (Y), unde un coeficient de pantă pozitiv ar indica faptul că un număr mai mare de ședințe de consiliere este asociat cu o stare de bine mai ridicată.

Pentru a evalua dacă coeficienții de regresie sunt semnificativi din punct de vedere statistic, se efectuează teste t pentru β_0 și β_1 . Aceste teste indică dacă coeficienții estimați diferă semnificativ de zero, ceea ce înseamnă că există o probabilitate redusă ca aceștia să fie rezultatul întâmplării. Dacă valoarea p asociată unui coeficient este mai mică decât un nivel de semnificație prestabilit (de obicei 0,05), coeficientul respectiv este considerat semnificativ, sugerând că relația dintre variabilă independentă și dependentă este probabil reală și nu rezultatul unor fluctuații aleatorii (Gaylor & Sweeny, 1965).

Valoarea de semnificație statistică este afectată de dimensiunea eșantionului și de variabilitatea datelor. În eșantioane mari, coeficienții de regresie semnificativi indică o relație consistentă între variabile, dar în eșantioane mici, semnificația statistică a coeficienților poate să fie mai puțin robustă, iar rezultatele să fie susceptibile la variații datorate dimensiunii limitate a eșantionului (Eberly, 2007). Este important de reținut că, deși semnificația statistică a unui coeficient indică existența unei relații între variabile, aceasta nu garantează că relația este puternică sau relevantă din punct de vedere practic. Prin urmare, interpretarea coeficienților de regresie necesită o analiză detaliată a valorii β_1 și a relevanței sale în contextul cercetării.

Interpretarea corectă a coeficienților de regresie este crucială pentru validitatea concluziilor statistice și fundamentarea deciziilor bazate pe date. Coeficientul de pantă β_1 oferă informații despre gradul și direcția influenței variabilei independente asupra variabilei dependente, dar această interpretare trebuie realizată ținând cont de specificul domeniului studiat și de ipotezele modelului de regresie. De exemplu, în educație, coeficientul de pantă al regresiei între numărul de ore de studiu și scorul la examene poate avea implicații pentru strategiile de învățare; un coeficient pozitiv ar putea încuraja alocarea mai multor ore pentru studiu, pe baza corelației identificate între aceste variabile.

Interpretarea interceptului β_0 , deși adesea omisă din discuțiile practice, poate furniza context pentru model și poate ajuta la evaluarea validității

acestui în punctele extreme ale variabilei independente. De exemplu, dacă un model include o valoare a lui X apropiată de zero și acest punct de referință este semnificativ pentru studiu, atunci interpretarea lui β_0 devine esențială pentru a înțelege nivelul de bază al variabilei Y în absența influenței variabilei independente.

În concluzie, interpretarea coeficienților de regresie nu este doar o simplă aplicare de formule statistice, ci un proces care implică o înțelegere profundă a domeniului de studiu și a contextului specific al analizei. Fiecare coeficient are implicații asupra concluziilor pe care cercetătorul le poate trage din model, iar interpretările trebuie realizate cu atenție pentru a asigura validitatea și relevanța rezultatelor obținute.

3.3. Aplicarea regresiei pentru predicția rezultatelor și verificarea modelului

Regresia liniară simplă este adesea utilizată pentru a face predicții bazate pe relația dintre o variabilă dependentă Y și o variabilă independentă X . Prin introducerea valorilor cunoscute ale variabilei independente X în ecuația de regresie, putem estima valorile așteptate ale variabilei dependente Y , având astfel capacitatea de a prezice rezultate viitoare în baza datelor existente. Ecuația de regresie, $Y = \beta_0 + \beta_1 X + \epsilon$, permite nu doar înțelegerea direcției și intensității relației dintre variabile, ci și predicția specifică a Y pentru orice valoare dată a lui X (Montgomery, Peck & Vining, 2021). Această capacitate de predicție este valoroasă în numeroase domenii, inclusiv în educație, psihologie și științele sociale, unde informațiile privind rezultatele viitoare sunt adesea critice pentru luarea deciziilor și dezvoltarea de intervenții.

Pentru a evalua dacă modelul de regresie liniară simplă este adecvat și produce estimări valide, se aplică mai multe tehnici de verificare care includ analiza rezidualelor, evaluarea coeficientului de determinare R^2 , testul F și analiza erorilor standard ale coeficienților. Verificarea modelului este o etapă crucială, deoarece numai un model bine ajustat va oferi predicții fiabile și interpretări corecte ale relației dintre variabile (Norouzian & Plonsky, 2018).

Reziduurile, sau diferențele dintre valorile observate ale lui Y și valorile estimate de model, sunt esențiale în evaluarea validității unui model de regresie. Analiza rezidualelor ajută la identificarea tiparelor și a eventualelor încălcări ale asumpțiilor de bază, precum liniaritatea,

homoscedasticitatea și normalitatea. Dacă modelul de regresie este adecvat, reziduurile ar trebui să fie distribuite aleatoriu în jurul liniei de zero într-un grafic al rezidualelor față de valorile prezise. Orice tipar sistematic, cum ar fi o curbă, ar putea sugera o relație neliniară între variabile, în timp ce o distribuție neuniformă a rezidualelor ar putea indica o problemă de heteroscedasticitate (Maulud & Abdulazeez, 2020).

Coeficientul de determinare (R^2) reprezintă proporția varianței totale din Y explicată de modelul de regresie în funcție de X . Acesta variază între 0 și 1, unde valori apropiate de 1 indică o potrivire excelentă a modelului, iar valori apropiate de 0 sugerează că modelul explică doar o mică parte din variabilitatea lui Y (James et al., 2023). De exemplu, un R^2 de 0.8 înseamnă că 80% din variația variabilei dependente este explicată de variabila independentă, ceea ce indică un model robust. Totuși, R^2 trebuie interpretat în contextul cercetării; un R^2 mai mic poate fi considerat adecvat în cercetarea socială sau în psihologie, unde comportamentele sunt de obicei influențate de factori multipli care nu sunt incluși în model.

Testul F este utilizat pentru a evalua semnificația globală a modelului de regresie, indicând dacă există o relație semnificativă între variabila dependentă Y și variabila independentă X . Testul compară variația explicată de model cu variația neexplicată, iar o valoare p asociată testului F mai mică de 0,05 sugerează că modelul este semnificativ per ansamblu. Acest lucru indică faptul că variabila independentă explică o parte semnificativă a varianței din variabila dependentă și că modelul de regresie poate fi considerat valid pentru predicții (Zou, Tuncali & Silverman, 2003).

Erorile standard asociate coeficienților de regresie indică precizia estimării acestora. Erorile standard mari sugerează instabilitate și nesiguranță în valorile estimate ale coeficienților, ceea ce poate compromite fiabilitatea modelului. Dacă erorile standard sunt mari, estimările coeficienților pot varia semnificativ între eșantioane diferite, indicând o fiabilitate scăzută a modelului. În astfel de cazuri, cercetătorii pot lua în considerare fie mărirea dimensiunii eșantionului pentru a reduce erorile standard, fie ajustarea modelului prin eliminarea valorilor extreme care pot afecta stabilitatea (Sedgwick, 2013).

Pentru a maximiza capacitatea de predicție și a asigura validitatea interpretărilor, este esențial ca modelul de regresie liniară simplă să fie ajustat și verificat corespunzător. Verificarea modelului prin analiza

rezidualelor, evaluarea R^2 , testul F și analiza erorilor standard ajută la detectarea posibilelor încălcări ale asumpțiilor și la asigurarea că modelul este stabil și robust. Un model de regresie bine ajustat nu oferă doar o înțelegere clară a relației dintre variabile, ci și capacitatea de a prezice cu un grad rezonabil de acuratețe valori viitoare ale variabilei dependente (Montgomery et al., 2021).

În concluzie, regresia liniară simplă rămâne o metodă fundamentală în cercetarea aplicată pentru investigarea relațiilor unidimensionale între variabile. Deși este o metodă accesibilă și ușor de aplicat, aplicarea sa corectă depinde de respectarea asumpțiilor fundamentale și de o verificare atentă a modelului. Aceste aspecte metodologice, alături de o interpretare riguroasă a coeficienților și a măsurilor de adecvare, asigură rezultate de înaltă calitate și predicții precise, contribuind la o fundamentare statistică solidă în diverse domenii de cercetare, precum educația, psihologia și asistența socială.

CAPITOLUL 4.

Regresia liniară multiplă și non-liniară (pătratică – curbilinie)

Regresia liniară multiplă și regresia non-liniară reprezintă evoluții și extinderi naturale ale modelului de regresie liniară simplă, având scopul de a surprinde și interpreta relații mai complexe între variabile. Într-o analiză de regresie multiplă, modelul permite includerea mai multor variabile independente (predictori), fiecare având un rol specific în explicarea varianței unei variabile dependente. În schimb, regresia non-liniară, cum este regresia polinomială, adaugă termeni de ordin superior pentru a modela relații curbilinii. Regresia logistică este un tip de regresie non-liniară, utilizată atunci când variabila dependentă este categorică. Aceste modele avansate extind capacitatea analitică a regresiei și sunt esențiale în multe domenii de cercetare, inclusiv educație, psihologie și asistență socială, unde fenomenele complexe necesită o abordare mai nuanțată decât cea oferită de regresia simplă.

Regresia liniară multiplă permite examinarea simultană a efectelor mai multor variabile independente asupra unei singure variabile dependente. Modelul este reprezentat prin ecuația: $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon$, unde β_0 este interceptul, iar $\beta_1, \beta_2, \dots, \beta_n$ sunt coeficienții asociați fiecărui predictor X_i , iar ϵ este termenul de eroare (Uyanık & Güler, 2013). Fiecare coeficient β_i măsoară schimbarea așteptată în Y asociată unei modificări unitare în X_i , menținând toate celelalte variabile constante. Această capacitate de a estima efectele independente ale predictorilor face din regresia multiplă un instrument puternic în studiul fenomenelor complexe.

În educație, regresia multiplă poate fi folosită pentru a analiza factorii care influențează performanța academică, cum ar fi motivația elevilor, sprijinul parental și resursele școlare. Fiecare coeficient de regresie din model indică impactul independent al fiecărui factor asupra performanței, permițând cercetătorilor să identifice contribuția specifică a fiecărei variabile.

În psihologie, regresia multiplă este adesea utilizată pentru a studia efectele multiplelor trăsături de personalitate asupra bunăstării psihologice, iar în asistența socială, poate examina cum variabilele socio-economice și accesul la servicii influențează sănătatea mentală a populației vulnerabile.

Regresia polinomială este un tip de regresie non-liniară utilizată pentru a modela relații curbilini între variabile. În regresia polinomială, ecuația include termeni de ordin superior ai variabilei independente, cum ar fi X^2 , X^3 , etc., pentru a surprinde forme de tip „U” sau „U inversat”. Modelul pătratic, de exemplu, are forma: $Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \epsilon$.

Acest model este util atunci când efectul predictorului asupra variabilei de răspuns nu este constant și liniar, ci crește sau scade în funcție de valoarea predictorului (Borradaile, 2003). În aplicare, regresia polinomială permite identificarea relațiilor non-liniare subtile, care pot fi esențiale pentru înțelegerea unor fenomene complexe.

În educație, regresia polinomială poate fi aplicată pentru a examina modul în care nivelul de studiu afectează performanța academică, unde un nivel moderat de studiu poate avea un impact pozitiv, dar studiul excesiv ar putea fi asociată cu o scădere a performanței datorită oboselii sau stresului. În psihologie, acest model poate fi folosit pentru a analiza relația dintre stres și sănătatea mentală; la niveluri moderate, stresul ar putea avea un efect motivațional, în timp ce nivelurile foarte ridicate sau foarte scăzute ale stresului pot afecta negativ sănătatea mentală. În asistența socială, curbiliniaritatea poate fi utilizată pentru a înțelege efectele complexe ale suportului social asupra calității vieții, unde un nivel moderat de suport poate fi optim, iar prea mult sau prea puțin suport poate să nu fie la fel de benefic (Ganzach, 1997).

Regresia logistică este o tehnică de regresie non-liniară folosită atunci când variabila dependentă este categorică, adesea binară (de exemplu, da/nu, succes/eșec). În regresia logistică, relația dintre variabila dependentă și predictorii săi este modelată prin funcția logit, care transformă probabilitatea unui eveniment într-o relație liniară: $\text{logit}(P(Y=1)) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$, unde $P(Y=1)$ este probabilitatea ca evenimentul de interes (de exemplu, succesul) să se producă (Barber & Thompson, 2004). Modelul logistic transformă probabilitatea într-un interval continuu (de la 0 la 1), oferind o interpretare intuitivă și precisă a relației dintre predictorii incluși și probabilitatea unui anumit rezultat.

Regresia logistică este aplicabilă în multiple domenii, având o relevanță deosebită pentru problemele de clasificare și predicție. În educație, poate fi utilizată pentru a prezice probabilitatea ca un elev să finalizeze studiile în funcție de factori demografici și academici. În psihologie, regresia logistică este utilizată pentru a examina factorii care influențează probabilitatea apariției unor tulburări mentale, cum ar fi depresia, în funcție de nivelul de stres și sprijin social. În asistența socială, această tehnică poate prezice probabilitatea ca o persoană să aibă acces la anumite servicii, pe baza caracteristicilor socio-economice și a altor factori contextuali.

Regresia multiplă și modelele non-liniare oferă o versatilitate crescută în analiza statistică, permițând cercetătorilor să exploreze și să interpreteze relații complexe între variabile multiple sau relații curbilinii și categorice între variabile. Spre deosebire de regresia simplă, aceste modele complexe necesită o înțelegere profundă a asumpțiilor, a metodologiilor de interpretare și a tehnicilor de optimizare pentru a asigura validitatea rezultatelor. Aplicarea lor corectă și atentă oferă un cadru analitic robust pentru înțelegerea și predicția rezultatelor în domenii precum educația, psihologia și asistența socială, contribuind la o mai bună fundamentare a deciziilor și intervențiilor bazate pe date.

4.1. Construcția și interpretarea modelelor de regresie multiplă

Regresia liniară multiplă este o extensie a regresiei liniare simple, destinată modelării relațiilor dintre o variabilă dependentă Y și mai multe variabile independente X_1, X_2, \dots, X_n . Modelul de regresie multiplă este utilizat pentru a descrie și a înțelege cum o combinație de predictorii influențează o variabilă dependentă, oferind o perspectivă mai detaliată asupra relațiilor complexe dintre variabile.

Modelul de regresie multiplă poate fi exprimat matematic prin următoarea ecuație:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon$$

unde:

- β_0 este interceptul (ordonata la origine), reprezentând valoarea estimată a lui Y atunci când toți predictorii X_i sunt egali cu zero.
- $\beta_1, \beta_2, \dots, \beta_n$ sunt coeficienții de regresie asociați fiecărei variabile independente X_1, X_2, \dots, X_n , care descriu efectul fiecărui predictor asupra lui Y , menținând toate celelalte variabile constante.
- ϵ este termenul de eroare, care captează variațiile din Y ce nu pot fi explicate de predictorii.

Fiecare coeficient β_i indică schimbarea așteptată în Y pentru o creștere unitară în X_i , în condițiile în care celelalte variabile independente rămân constante (Uyanık & Güler, 2013). Acest lucru face din regresia multiplă un model deosebit de util în cercetarea socială, unde variabilele sunt adesea interdependente.

În interpretarea unui model de regresie multiplă, este esențial să se ia în considerare contextul în care fiecare coeficient este analizat. De exemplu, în domeniul educației, putem construi un model pentru a prezice performanța academică (Y) în funcție de mai mulți factori: ore de studiu (X_1), motivație (X_2), și sprijin parental (X_3). În acest caz, coeficientul β_1 pentru orele de studiu ar indica modificarea așteptată în performanța academică pentru o creștere de o oră în timpul de studiu, ținând constant sprijinul parental și motivația.

În psihologie, un model de regresie multiplă ar putea fi folosit pentru a analiza relația dintre sănătatea mintală (Y) și o serie de factori precum nivelul de stres (X_1), sprijinul social (X_2) și activitatea fizică (X_3). Fiecare coeficient din modelul de regresie ar indica impactul specific al fiecărui factor asupra sănătății mintale, izolat de influența celorlalte variabile. Interpretarea coeficienților permite astfel identificarea predictorilor cei mai importanți și analiza rolului fiecăruia în influențarea variabilei dependente.

Un aspect esențial în interpretarea regresiei multiple este colinearitatea, care apare atunci când variabilele independente sunt corelate între ele. Colinearitatea poate duce la instabilitatea estimărilor coeficienților și la dificultăți în a izola efectele individuale ale fiecărui predictor (Marill, 2004). Dacă predictorii au o colinearitate ridicată, interpretarea independentă a fiecărui coeficient devine problematică, iar modelul poate deveni sensibil la mici schimbări ale datelor.

Pentru a detecta și gestiona colinearitatea, cercetătorii pot utiliza indicele de toleranță și factorul de inflație a varianței (VIF), care măsoară nivelul de colinearitate din model. Dacă VIF-ul este ridicat (de exemplu, peste 10), este recomandată reducerea predictorilor corelați pentru a îmbunătăți stabilitatea și interpretabilitatea modelului (Jobson, 1991). O soluție comună pentru reducerea colinearității este eliminarea variabilelor redundante sau utilizarea tehnicilor de regularizare, cum ar fi regresia ridge sau Lasso (Krzywinski & Altman, 2015).

Pentru a evalua semnificația coeficienților dintr-un model de regresie multiplă, se utilizează teste *t* pentru fiecare coeficient în parte. Aceste teste ajută la determinarea dacă fiecare variabilă independentă are o relație semnificativă cu variabila dependentă. Dacă valoarea *p* a unui coeficient este sub pragul de semnificație (de obicei 0,05), acesta poate fi considerat un predictor semnificativ. De exemplu, într-un studiu de asistență socială care analizează accesul la servicii în funcție de venituri, nivelul de educație și locația geografică, coeficienții semnificativi ar arăta care dintre acești factori are un impact real asupra accesului la servicii.

Interpretarea riguroasă a coeficienților necesită, de asemenea, evaluarea coeficientului de determinare R^2 , care indică proporția din variația lui *Y* explicată de model. Un R^2 ridicat sugerează că predictorii incluși în model explică o mare parte din variația variabilei dependente, în timp ce un R^2 scăzut indică faptul că variabila dependentă este influențată de factori care nu sunt incluși în model (Slinker & Glantz, 1988). Totuși, interpretarea R^2 depinde de context, deoarece, în unele domenii, variațiile comportamentale pot fi influențate de multiple surse neincluse în model, ceea ce face ca un R^2 mai scăzut să fie acceptabil.

Regresia multiplă este un instrument de bază în analiza statistică aplicată, fiind utilizată frecvent pentru a evalua relațiile între variabile în cercetarea socială, psihologică și educațională. În educație, modelul poate identifica factorii care influențează performanța școlară sau implicarea elevilor în activități extracurriculare, contribuind astfel la formularea de politici educaționale. În psihologie, este util în studiul factorilor care afectează sănătatea mintală, cum ar fi sprijinul social și stresul, oferind date esențiale pentru dezvoltarea programelor de intervenție. În asistența socială, modelul de regresie multiplă poate fi folosit pentru a analiza efectul

variabilelor socio-economice asupra accesului la servicii și asupra calității vieții populațiilor vulnerabile.

Totuși, aplicarea regresiei multiple implică o atenție sporită la asumțiile modelului, cum ar fi liniaritatea, independența observațiilor și homoscedasticitatea. Nerespectarea acestor asumții poate afecta validitatea modelului și poate duce la interpretări incorecte. De asemenea, colinearitatea între predictorii modelului poate complica interpretarea rezultatelor și poate necesita ajustări ale modelului.

În concluzie, regresia liniară multiplă oferă o abordare statistică riguroasă și versatilă pentru analiza relațiilor complexe dintre variabile. Printr-o construcție atentă și o interpretare riguroasă, modelul de regresie multiplă permite o înțelegere aprofundată a factorilor care influențează rezultatele studiate, oferind un cadru analitic robust pentru cercetătorii din diverse domenii.

4.2. Regresia polinomială și logistică: definiție și aplicații

Regresia polinomială și regresia logistică sunt două abordări statistice esențiale pentru analiza relațiilor non-liniare, fiecare având aplicații specifice și relevante în diverse domenii. Spre deosebire de regresia liniară simplă sau multiplă, care modelează relații liniarizabile între variabile, aceste metode sunt concepute pentru a surprinde și a interpreta efectele complexe și curbiliniile sau pentru a trata variabile dependente categorice.

Regresia polinomială este o formă de regresie non-liniară care permite modelarea relațiilor curbiliniile între variabile. Aceasta este deosebit de utilă atunci când relația dintre variabila independentă și variabila dependentă nu este liniară, ci are o formă curbată, adică o relație în care schimbările în variabila dependentă Y nu sunt proporționale cu modificările din variabila independentă X . Modelul polinomial este exprimat prin ecuația generală:

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_n X^n + \epsilon$$

unde X^2, X^3, \dots, X^n sunt termeni de ordin superior, iar $\beta_0, \beta_1, \dots, \beta_n$ sunt coeficienți care reprezintă contribuțiile fiecărui termen la valoarea estimată a lui Y . Termenii de ordin superior introduc curbiliniaritatea în model, ceea ce

permite captarea unor tipare mai complexe decât ar putea realiza o regresie liniară simplă (Kondrič et al., 2013).

Un model pătratic, de exemplu, cu termenul X^2 , este adesea folosit pentru a surprinde relații de tip „U” sau „U inversat”, unde efectul predictorului asupra variabilei de răspuns crește sau scade până la un punct de inflexiune, după care începe să scadă sau să crească invers. Această caracteristică este utilă în multe domenii. În educație, de exemplu, regresia polinomială poate fi utilizată pentru a analiza relația dintre intensitatea studiului și performanța academică; în acest context, un nivel moderat de studiu ar putea avea un efect pozitiv asupra performanței, dar un număr extrem de mare de ore de studiu ar putea să scadă performanța din cauza oboselii și a stresului. În psihologie, curbiliniaritatea poate fi utilă în studiul efectului stresului asupra sănătății mentale. Până la un anumit punct, stresul poate avea un efect motivațional, dar la niveluri ridicate, acesta poate deveni dăunător (Ganzach, 1997).

Totuși, utilizarea regresiei polinomiale trebuie realizată cu atenție, deoarece adăugarea unor termeni de ordin superior poate duce la suprapotrivirea modelului, în care acesta devine excesiv de adaptat la datele de antrenament și nu mai generalizează corect pe seturi de date noi. Suprapotrivirea reduce capacitatea modelului de a produce predicții precise, iar un model prea complex poate descrie variații nesemnificative ale datelor, mai degrabă decât relația reală dintre variabile (Berk & Booth, 1995). Pentru a preveni acest lucru, cercetătorii pot folosi metode de validare, cum ar fi cross-validation, pentru a evalua performanța modelului pe seturi de date independente.

Regresia logistică este o metodă de regresie non-liniară aplicată atunci când variabila dependentă este categorică, cel mai frecvent binară (de exemplu, succes/eșec, prezent/absent). În regresia logistică, scopul nu este să se prezică o valoare numerică exactă, ci să se estimeze probabilitatea ca un eveniment să aibă loc (de exemplu, probabilitatea de a prezenta un anumit comportament). Modelul logistic folosește funcția logit pentru a transforma probabilitatea unui eveniment într-o relație liniară: $\text{logit}(P(Y=1)) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$, unde $P(Y=1)$ reprezintă probabilitatea ca Y să fie egal cu 1, iar variabilele independente X_1, X_2, \dots, X_n contribuie la această probabilitate. Transformarea logit, care aplică logaritmul probabilităților, permite ca valorile prezise ale lui Y să fie limitate

între 0 și 1, ceea ce reflectă caracterul probabilistic al modelului (Barber & Thompson, 2004).

Regresia logistică este extrem de utilă în analizele unde rezultatele sunt categorice, permițând cercetătorilor să identifice factorii care influențează probabilitatea apariției unui eveniment. În educație, de exemplu, regresia logistică poate fi utilizată pentru a prezice probabilitatea ca un elev să finalizeze studiile, în funcție de factori demografici, nivelul de pregătire academică și sprijinul parental. În psihologie, regresia logistică poate examina efectul unor factori, cum ar fi sprijinul social și nivelul de stres, asupra probabilității ca o persoană să dezvolte simptome de depresie (Kelley & Bolin, 2013). În asistența socială, acest model poate fi aplicat pentru a analiza probabilitatea ca anumite categorii de populație să acceseze servicii de sprijin în funcție de caracteristicile socio-economice.

Interpretarea coeficienților în regresia logistică este diferită de cea din regresia liniară, deoarece aceștia măsoară efectul fiecărei variabile independente asupra logit-ului probabilității, nu direct asupra probabilității în sine. Un coeficient pozitiv indică faptul că, pe măsură ce variabila independentă crește, probabilitatea ca evenimentul să aibă loc (adică, $Y=1$) crește, în timp ce un coeficient negativ sugerează o relație inversă. În aplicațiile practice, coeficienții de regresie logistică sunt adesea interpretați în termeni de odds ratios (raportul șanselor), care cuantifică de câte ori probabilitatea de apariție a unui eveniment se schimbă pentru fiecare unitate de creștere a predictorului.

Atât regresia polinomială, cât și cea logistică sunt instrumente valoroase în analizarea relațiilor complexe dintre variabile, fiecare având aplicații specifice în funcție de tipul și natura datelor analizate. Totuși, fiecare metodă vine cu limitări și necesită o atenție deosebită în interpretare. Regresia polinomială, de exemplu, poate deveni inefficientă dacă sunt incluși prea mulți termeni de ordin superior, ceea ce complică modelul fără a aduce informații relevante (Borradaile, 2003). De asemenea, regresia logistică poate avea probleme de interpretare atunci când datele sunt dezechilibrate (de exemplu, un număr mult mai mare de observații într-o categorie decât în cealaltă), ceea ce necesită ajustări speciale ale modelului pentru a obține rezultate valide.

În concluzie, regresia polinomială și logistică extind semnificativ capacitățile analitice ale cercetătorilor, permițând studierea unor relații non-

liniare și probabilistice într-o varietate de domenii. Aceste modele oferă perspective complexe și utile asupra modului în care variabilele explicative influențează rezultatele, asigurând un cadru metodologic robust pentru decizii informate și evaluări precise în educație, psihologie și asistență socială.

4.3. Testarea asumpțiilor și optimizarea modelelor de regresie complexă

Pentru a asigura validitatea modelelor de regresie multiplă și non-liniară, este esențial să se testeze și să se respecte anumite asumpții statistice. Aceste asumpții contribuie la integritatea modelului și la capacitatea acestuia de a furniza rezultate corecte și generalizabile. Principalele asumpții includ liniaritatea relației în regresia multiplă, independența observațiilor, homoscedasticitatea rezidualelor și normalitatea rezidualelor.

Asumpția liniarității implică faptul că fiecare variabilă independentă ar trebui să aibă o relație liniară cu variabila dependentă, ceea ce înseamnă că efectul predictorilor asupra variabilei de răspuns trebuie să fie proporțional și constant. În regresia multiplă, această condiție este fundamentală, întrucât relația liniară între predictor și răspuns permite interpretarea directă a coeficienților de regresie (Rodrigues, 2021). Pentru modelele polinomiale, însă, termenii de ordin superior (X_2 , X_3) sunt adăugați tocmai pentru a surprinde natura curbilinie a relației, relaxând astfel cerința unei relații strict liniare și permițând modelului să descrie relații mai complexe.

În cercetarea aplicată, asigurarea liniarității poate fi verificată grafic prin diagrame de dispersie sau diagrame reziduale. De exemplu, în psihologie, modelarea efectului stresului asupra sănătății mentale poate necesita un termen de ordin superior pentru a surprinde curbilinearitatea, deoarece efectele stresului nu sunt uniforme la niveluri scăzute și ridicate.

Independența observațiilor este o altă asumpție esențială pentru modelele de regresie, și ea presupune că observațiile individuale nu sunt corelate între ele. Nerespectarea independenței poate introduce erori sistematice, afectând semnificativ estimările coeficienților și crescând riscul unor concluzii inexacte (Cortina, 1993). În practică, această asumpție poate fi mai greu de asigurat în datele obținute prin studii longitudinale sau de tip panel, unde aceleași persoane sunt analizate în timp.

Homoscedasticitatea, sau varianța constantă a rezidualelor, presupune că reziduurile (diferențele dintre valorile observate și cele prezise de model) au o varianță constantă pe întreaga gamă a valorilor predicțiilor. Dacă reziduurile prezintă o varianță variabilă în funcție de nivelul variabilei independente, modelul suferă de heteroscedasticitate, ceea ce poate afecta acuratețea testelor de semnificație și a estimărilor intervalelor de încredere. Un exemplu clasic de heteroscedasticitate ar putea apărea în studii educaționale, unde variația performanței academice ar putea fi mai mare pentru elevii cu rezultate scăzute față de cei cu rezultate ridicate.

Verificarea homoscedasticității se poate face grafic, printr-un grafic rezidual care ar trebui să arate o distribuție uniformă a rezidualelor în jurul liniei de zero. Încălcarea acestei asumptii poate necesita metode corective, cum ar fi transformarea datelor sau utilizarea unor modele robuste.

Normalitatea rezidualelor este importantă mai ales în evaluarea semnificației coeficienților și pentru construirea intervalelor de încredere. Dacă reziduurile sunt distribuite normal, estimările coeficienților sunt mai precise și teste statistice, cum ar fi testul t , sunt aplicabile. În practică, această asumptie este verificată prin histograme sau grafice Q-Q ale rezidualelor. În domeniul precum psihologia, unde datele pot fi deseori asimetrice, încălcarea asumptiei de normalitate poate fi ajustată prin transformări ale datelor sau prin utilizarea unor metode statistice neparametrice.

Colinearitatea apare atunci când două sau mai multe variabile independente sunt puternic corelate, ceea ce face dificilă izolarea efectului fiecărei variabile asupra variabilei dependente. Colinearitatea ridicată reduce precizia estimării coeficienților și poate conduce la instabilitatea modelului, făcându-l sensibil la mici variații ale datelor (Hanley, 2016). Colinearitatea se poate verifica folosind factorul de inflație a varianței (VIF), care cuantifică cât de mult este crescută varianța estimării coeficientului datorită colinearității.

În analiza aplicată, cum ar fi studiile sociale și psihologice, colinearitatea poate afecta interpretarea rezultatelor. De exemplu, în analiza satisfacției în muncă, variabilele precum sprijinul din partea colegilor și motivația intrinsecă pot fi corelate, iar eliminarea uneia dintre ele sau utilizarea tehnicilor de regularizare, precum regresia Lasso, poate ajuta la clarificarea rezultatelor (Krzywinski & Altman, 2015).

Optimizarea modelului este un pas crucial pentru a asigura performanța și generalizarea acestuia. Suprapotrivirea (overfitting) apare atunci când modelul se adaptează prea mult la datele de antrenament, captând variații ne semnificative și pierzându-și capacitatea de a generaliza pe noi seturi de date. Aceasta este o problemă comună în regresia multiplă, mai ales atunci când sunt incluse prea multe variabile independente sau termeni de ordin superior.

O tehnică de prevenire a suprapotrivirii este cross-validation, prin care datele sunt împărțite în subseturi de antrenament și de testare, evaluând astfel performanța modelului pe date necunoscute. Cross-validation este o metodă robustă de optimizare a modelului și poate ajuta la identificarea celui mai simplu model care încă explică variația variabilei dependente (Breiman & Friedman, 1997).

Testarea riguroasă a asumpțiilor și optimizarea sunt esențiale pentru validitatea modelelor de regresie multiplă și non-liniară. Verificarea liniarității, independenței observațiilor, homoscedasticității și normalității rezidualelor, precum și gestionarea colinearității și prevenirea suprapotrivirii, asigură interpretări corecte și o fiabilitate crescută a modelului. În educație, psihologie și asistență socială, respectarea acestor practici metodologice îmbunătățește calitatea analizei și contribuie la fundamentarea deciziilor și intervențiilor bazate pe date.

CAPITOLUL 5.

Introducere în mediere: simplă, paralelă, secvențială

Medierea este o metodă analitică centrală în statistica aplicată, destinată înțelegerii mecanismelor subtile prin care o variabilă independentă (X) influențează o variabilă dependentă (Y) printr-o variabilă intermediară, cunoscută ca variabilă de mediere (M). Această metodă permite cercetătorilor să investigheze nu doar relația directă dintre predictor și variabila de răspuns, ci și impactul indirect exercitat prin intermediul mediatorului. Scopul analizei de mediere este de a oferi o perspectivă detaliată asupra relațiilor dintre variabile, furnizând informații suplimentare despre modul în care procesele complexe influențează rezultatele într-un mod mai subtil și mai comprehensiv decât prin analiza directă (Hayes, 2009; MacKinnon, 2012).

De exemplu, într-un studiu asupra impactului sprijinului parental asupra succesului academic al elevilor, motivația elevilor poate acționa ca o variabilă de mediere. În acest caz, efectul sprijinului parental asupra performanței academice ar putea fi parțial sau complet explicat prin influența pozitivă pe care sprijinul o are asupra motivației elevilor. Prin utilizarea analizei de mediere, cercetătorii pot cuantifica atât efectul direct al sprijinului parental asupra performanței academice, cât și efectul indirect mediat de motivație.

Există mai multe tipuri de analiză de mediere, fiecare cu aplicații specifice și utilizări adecvate în funcție de complexitatea relațiilor dintre variabile. Acestea includ medierea simplă, medierea paralelă și medierea secvențială (sau serială). Fiecare tip de mediere adaugă o dimensiune suplimentară în interpretarea efectelor indirecte și în explorarea căilor multiple prin care o variabilă predictor poate influența o variabilă de răspuns.

Medierea simplă implică un singur mediator (M) care explică parțial sau complet relația dintre variabila predictor (X) și variabila dependentă (Y). Relația este de obicei descrisă în termeni de „efect indirect” și „efect direct”, unde efectul indirect reprezintă influența variabilei X asupra variabilei Y prin intermediul M , iar efectul direct este relația dintre X și Y , independent de M (Hayes & Preacher, 2014). Modelul matematic al medierii simple este relativ ușor de implementat și interpretează efectul indirect ca produs al coeficienților de regresie dintre variabile.

Medierea paralelă extinde modelul simplu prin includerea a doi sau mai mulți mediatori independenți (M_1, M_2, \dots, M_n) care acționează simultan asupra relației dintre X și Y . Acești mediatori nu influențează unii pe alții, ci fiecare acționează pe o cale separată de mediere. De exemplu, într-un studiu de psihologie organizațională, sprijinul din partea colegilor și satisfacția la locul de muncă ar putea fi doi mediatori paraleli prin care condițiile de muncă influențează motivația profesională (Swanzy, 2020). Fiecare mediator contribuie independent la efectul indirect total, iar suma efectelor indirecte individuale indică influența cumulativă a variabilelor de mediere asupra relației dintre X și Y .

Medierea secvențială, cunoscută și sub denumirea de mediere serială, implică o succesiune de mediatori care formează o relație cauzală în lanț între X și Y . În acest model, mediatori precum M_1 și M_2 sunt legați în serie, unde M_1 influențează M_2 , iar M_2 influențează direct Y . Acest model este folosit pentru a captura procesele complexe în care influențele se desfășoară în etape succesive. De exemplu, în domeniul educațional, stresul resimțit de elevi ar putea influența performanța academică prin intermediul stimei de sine și al suportului social, fiecare acționând ca un mediator secvențial în lanț (Charalambous et al., 2019).

Modelele de mediere secvențială sunt utile în studiile de asistență socială și psihologie, unde efectele se transmit printr-o succesiune de factori, permițând o analiză mai granulară a influențelor multiple. Modelarea unui efect indirect serial permite cercetătorilor să identifice ordinea în care variabilele intermediare influențează relația dintre variabila predictor și variabila de răspuns, oferind o înțelegere mai profundă a cauzalității.

În SPSS, modelarea PROCESS dezvoltat de Andrew F. Hayes oferă suport pentru analiza celor trei tipuri principale de mediere – simplă, paralelă și secvențială – oferind cercetătorilor un cadru eficient pentru

modelarea efectelor indirecte și interpretarea relațiilor complexe dintre variabile.

- **Medierea simplă (Modelul 4):** Modelul 4 este destinat medierii simple, unde se evaluează relația dintre o variabilă predictor și o variabilă dependentă prin intermediul unui singur mediator. Acest model calculează atât efectul direct (relația dintre predictor și variabila dependentă independent de mediator), cât și efectul indirect (influența predictorului asupra variabilei dependente prin mediator). Este o alegere frecventă în cercetările care urmăresc să identifice o cale indirectă simplă prin care predictorul influențează variabila dependentă.
- **Medierea paralelă (Modelul 4 cu mai mulți mediatori):** Modelul 4 din PROCESS poate fi extins pentru analiza medierii paralele, permițând includerea a mai multor mediatori (până la patru) care acționează simultan, dar independent, între variabila predictor și variabila dependentă. Fiecare mediator contribuie la efectul indirect al predictorului pe o cale separată, fără a influența alte medieri. Acest model este ideal pentru cazurile în care se dorește examinarea influenței simultane a mai multor mediatori asupra relației dintre predictor și variabila dependentă.
- **Medierea secvențială (Modelul 6):** Modelul 6 din PROCESS este destinat medierii secvențiale (seriale), permițând analiza unei succesiuni de până la patru mediatori care acționează într-un lanț causal între variabila predictor și variabila dependentă. În acest model, fiecare mediator influențează următorul, creând o cale indirectă complexă prin care efectul predictorului este transmis către variabila dependentă. Modelul este potrivit pentru situațiile în care variabilele intermediare sunt ordonate într-o succesiune de etape, permițând o explorare detaliată a relațiilor cauzale complexe.

Modelarea cu PROCESS în SPSS facilitează configurarea și analiza acestor modele, oferind rezultate comprehensive pentru interpretarea efectelor directe și indirecte într-un mod clar și sistematic.

Analiza de mediere este un instrument deosebit de valoros în cercetările din educație, psihologie și asistență socială, unde procesele sunt adesea interconectate și multifactoriale. De exemplu, în educație, analiza de mediere poate fi folosită pentru a înțelege cum diferitele tipuri de sprijin

(sprijinul parental, resursele școlare) influențează succesul academic prin intermediul variabilelor precum motivația sau autoeficacitatea. În psihologie, este utilă pentru explorarea modului în care trăsăturile de personalitate, cum ar fi anxietatea, pot influența comportamentul social prin mediatori precum stima de sine. În asistența socială, analiza de mediere ajută la explorarea impactului suportului social asupra bunăstării indivizilor vulnerabili, prin intermediul factorilor cum ar fi stima de sine și percepția suportului comunitar (Iacobucci, 2008; Cuc et al., 2022).

Deși analiza de mediere oferă perspective profunde asupra relațiilor dintre variabile, trebuie luate în considerare și limitările sale. În special, este necesară verificarea asumțiilor, cum ar fi independența mediatoarelor în cazul medierii paralele sau secvențiale, pentru a evita concluzii eronate (Pek & Hoyle, 2016). De asemenea, testarea și interpretarea efectelor indirecte necesită tehnici statistice robuste, cum ar fi procedurile de bootstrap, pentru a asigura stabilitatea estimărilor (Memon et al., 2018). Aceste limitări impun o abordare atentă și metodologică în implementarea și interpretarea modelelor de mediere, mai ales în contexte complexe și aplicate.

Capitolul prezintă analiza de mediere, oferind o bază teoretică și practică pentru cercetători înțelegerea efectelor indirecte. În continuare, capitolele vor explora în detaliu fiecare tip de mediere, oferind exemple și metode specifice de interpretare. Analiza de mediere continuă să fie un instrument esențial pentru cercetătorii care doresc să capteze relațiile dinamice dintre variabile și să ofere concluzii bine fundamentate pentru sprijinirea intervențiilor în educație, psihologie și asistență socială.

5.1. Conceptul de mediere: înțelegerea variabilelor intermediare

Conceptul de mediere a fost dezvoltat pentru a explora efectele indirecte și a oferi o perspectivă detaliată asupra modului în care variabilele se influențează reciproc în mod complex. Medierea oferă o alternativă analitică la modelele de relație directă, permițând evaluarea efectelor indirecte și identificarea variabilelor de mediere, care acționează ca „transmițători” ai influenței unei variabile independente (X) asupra unei variabile dependente (Y) (Hayes, 2009). În acest model, o variabilă de mediere (M) ajută la explicarea motivului pentru care X influențează Y , oferind detalii asupra procesului prin care se transmit efectele predictorului.

În analiza de mediere clasică, modelul propus de Baron și Kenny (1986) este considerat fundamental. Acesta presupune patru etape esențiale pentru a determina dacă o variabilă are un efect de mediere:

Relația între variabila independentă (X) și variabila dependentă (Y): Testarea relației directe dintre X și Y pentru a determina dacă există o asociere semnificativă.

$$Y = \beta_1 X + \epsilon_1$$

unde β_1 este coeficientul care măsoară influența directă a lui X asupra lui Y și ϵ_1 este eroarea de reziduală.

Relația între variabila independentă (X) și variabila de mediere (M): Testarea dacă X influențează mediatorul M , adică dacă există o relație semnificativă între X și M .

$$M = \alpha_1 X + \epsilon_2$$

unde α_1 este coeficientul de regresie care măsoară influența lui X asupra lui M , iar ϵ_2 este eroarea reziduală.

Relația dintre variabila de mediere (M) și variabila dependentă (Y), controlând pentru X : Aceasta implică testarea efectului lui M asupra lui Y atunci când variabila X este controlată.

$$Y = \beta_2 X + \beta_3 M + \epsilon_3$$

unde β_2 măsoară efectul direct al lui X asupra lui Y , iar β_3 măsoară influența mediatorului M asupra variabilei dependente Y .

Reducerea efectului direct al lui X asupra lui Y : Pentru a concluziona că există un efect de mediere, este necesar ca influența directă a lui X asupra lui Y (coeficientul β_2) să fie redusă semnificativ atunci când M este inclus în model. Dacă influența directă devine ne semnificativă, se consideră că medierea este completă; în caz contrar, avem de-a face cu o mediere parțială (MacKinnon, 2012).

În analiza de mediere, relația dintre variabile poate fi descrisă prin două tipuri de efecte:

Efectul direct (β_2) reprezintă influența lui X asupra lui Y independent de variabila mediator M .

Efectul indirect este produsul dintre coeficientul de regresie care măsoară influența lui X asupra lui M (α_1) și coeficientul care măsoară influența lui M asupra lui Y (β_3). Astfel, efectul indirect poate fi reprezentat matematic prin:

$$\text{Efect indirect} = \alpha_1 \cdot \beta_3$$

Acest efect indirect este semnificativ dacă valoarea sa diferă de zero, indicând că mediatorul M transmite o parte din influența lui X asupra lui Y . Testarea semnificației efectului indirect se poate face folosind tehnici de bootstrap, care estimează intervalele de încredere ale acestui efect și asigură o estimare mai robustă (Hayes & Preacher, 2014).

În domeniul educațional, modelul de mediere poate fi folosit pentru a analiza modul în care sprijinul parental (X) influențează performanța academică (Y) prin intermediul motivației (M). Conform acestui model, sprijinul parental ar trebui să aibă o influență semnificativă asupra motivației elevilor (relația $X \rightarrow M$) și, la rândul său, motivația ar trebui să aibă o influență asupra performanței academice (relația $M \rightarrow Y$). În acest fel, se poate determina dacă motivația funcționează ca o variabilă intermediară care explică de ce și cum sprijinul parental ajută la îmbunătățirea performanței academice.

În psihologie, analiza de mediere este esențială pentru a înțelege cum factori precum stresul influențează starea de sănătate prin mecanisme psihologice, cum ar fi autoeficacitatea. De exemplu, stresul (variabila predictor X) ar putea afecta sănătatea mentală (Y) prin scăderea autoeficacității (M). În acest context, autoeficacitatea ar explica o parte din efectul stresului asupra sănătății mentale, oferind informații valoroase pentru intervențiile psihologice.

În asistența socială, variabilele de mediere sunt adesea folosite pentru a explora modul în care diferite intervenții afectează bunăstarea indivizilor

prin factori psihosociali intermediari. De exemplu, suportul comunitar (predictor X) ar putea avea un efect asupra stimei de sine (Y) prin intermediul sentimentului de apartenență (M). În această situație, sentimentul de apartenență acționează ca o variabilă de mediere care poate ajuta la explicarea modului în care suportul comunitar contribuie la îmbunătățirea stimei de sine și, implicit, la o stare de bine generală.

Deși analiza de mediere oferă o înțelegere aprofundată a relațiilor indirecte, aceasta vine și cu limitări. Este important ca mediul de analiză să respecte anumite asumții, cum ar fi liniaritatea și absența colinearității excesive între variabile. În plus, interpretarea corectă a efectelor indirecte și directe depinde de testarea semnificației statistice a acestora, întrucât efectele indirecte nesemnificative pot duce la concluzii eronate.

5.2. Medierea simplă: metode de analiză și interpretare a efectelor indirecte

Medierea simplă reprezintă o abordare analitică esențială în studiul efectelor indirecte, utilizată pe scară largă în domeniile psihologiei și științelor sociale pentru a examina cum o variabilă predictor (X) influențează o variabilă dependentă (Y) prin intermediul unei singure variabile de mediere (M). Acest model este conceput pentru a testa ipoteza că o parte din influența lui X asupra lui Y se transmite indirect prin M , iar rezultatul acestei analize ajută cercetătorii să înțeleagă mecanismele psihologice și comportamentale subtile care determină relațiile între variabile (Hayes & Preacher, 2014).

Procedura de analiză a medierii simple constă în estimarea unei serii de coeficienți de regresie care cuantifică relațiile dintre predictor, mediator și variabila dependentă. Relațiile sunt descrise de trei coeficienți principali: efectul a , efectul b , și efectul c' , care permit identificarea și interpretarea efectelor indirecte și directe.

Efectul a : Acest coeficient reprezintă relația dintre variabila independentă X și variabila de mediere

M . Mai exact, coeficientul a măsoară impactul predictorului X asupra mediatorului M și se estimează prin modelul de regresie:

$$M = aX + \epsilon_M$$

unde ϵ_M reprezintă eroarea reziduală. Dacă efectul a este semnificativ, înseamnă că variabila independentă X influențează M , adică există o relație între predictor și mediator.

Efectul b : Acest coeficient cuantifică relația dintre variabila de mediere M și variabila dependentă Y , controlând pentru influența lui X . Efectul b se estimează prin modelul:

$$Y=bM+c'X+\epsilon_Y$$

unde c' este coeficientul de regresie care măsoară efectul direct al lui X asupra lui Y atunci când M este inclus în model, iar ϵ_Y reprezintă eroarea reziduală. Semnificația coeficientului b indică dacă mediatorul M are o influență semnificativă asupra variabilei dependente Y , independent de predictor.

Efectul c' : Acesta reprezintă efectul direct al predictorului X asupra variabilei dependente Y , ajustat pentru influența mediatorului M . Efectul direct (c') descrie relația dintre X și Y independent de M și este utilizat pentru a evalua dacă M explică parțial sau complet efectul predictorului asupra variabilei de rezultat.

Efectul indirect ($a \times b$): Efectul indirect este produsul dintre coeficientul a și coeficientul b și descrie porțiunea din influența lui X asupra lui Y care este transmisă prin M . Dacă $a \times b$ este semnificativ, aceasta sugerează că există o mediere, adică o relație indirectă între predictor și variabila dependentă prin intermediul mediatorului. Formula matematică pentru efectul indirect este:

$$\text{Efect indirect} = a \times b$$

Interpretarea efectului indirect se face de obicei prin testarea semnificației statistice, de exemplu, utilizând tehnica de bootstrap.

Pentru a determina dacă efectul indirect este semnificativ, se utilizează adesea metoda bootstrap, care implică generarea unui număr mare de eșantioane din datele originale, calcularea efectului indirect pentru fiecare eșantion și apoi construirea unui interval de încredere pe baza acestor estimări (Rucker et al., 2011). Dacă intervalul de încredere pentru $a \times b$ nu include valoarea zero, efectul indirect este considerat semnificativ.

Metoda bootstrap este preferată deoarece nu presupune o distribuție normală a efectului indirect, asigurând astfel estimări mai robuste. Aceasta este deosebit de utilă în studii psihologice și sociale, unde datele pot să nu respecte întotdeauna distribuția normală și să includă variabile cu relații complexe.

În cercetările din psihologie, modelul de mediere simplă poate fi utilizat pentru a analiza modul în care stresul (X) afectează performanța academică (Y) prin intermediul motivației (M). În acest exemplu, coeficientul a ar descrie relația dintre stres și motivație, arătând cum stresul influențează nivelul de motivație. Coeficientul b ar măsura relația dintre motivație și performanța academică, independent de stres. Dacă produsul $a \times b$ este semnificativ, aceasta sugerează că stresul afectează performanța academică indirect, prin influențarea motivației. Analiza unui astfel de efect indirect poate oferi perspective importante asupra modalităților de intervenție pentru a ameliora performanța academică prin reducerea stresului și creșterea motivației elevilor.

În asistența socială, medierea simplă poate ajuta la investigarea modului în care suportul social (X) influențează sănătatea mentală (Y) prin intermediul stimei de sine (M). Dacă suportul social crește stima de sine (efectul a), iar o stimă de sine mai ridicată îmbunătățește sănătatea mentală (efectul b), efectul indirect $a \times b$ ar evidenția o cale prin care suportul social contribuie la bunăstarea mentală. Acest tip de analiză este crucial pentru dezvoltarea intervențiilor sociale orientate spre îmbunătățirea sănătății mentale prin promovarea suportului social.

Este important de menționat că analiza medierii simple presupune îndeplinirea anumitor asumții statistice, cum ar fi liniaritatea relațiilor dintre variabile și independența observațiilor. De asemenea, variabila mediator M nu ar trebui să fie puternic coliniară cu predictorul X , deoarece colinearitatea poate duce la coeficienți instabili și interpretări eronate. În plus, semnificația statistică a efectului indirect nu garantează un efect causal. Pentru a stabili cauzalitatea, este necesar să existe un raționament teoretic solid și o secvențiere temporală corectă între variabile, astfel încât să fie respectate criteriile necesare de cauzalitate.

5.3. Modele de mediere paralelă și secvențială: diferențe și aplicații practice

Medierea paralelă și secvențială sunt extinderi ale modelului de mediere simplă, care implică mai mulți mediatori pentru a surprinde relații mai complexe între variabile. Medierea paralelă presupune că mai multe variabile de mediere acționează simultan, fără a se influența reciproc. Fiecare mediator contribuie independent la efectul indirect total. Un astfel de model poate fi util pentru a evalua efectele multiple și independente ale mai multor variabile de mediere (Kane & Ashbaugh, 2017). De exemplu, Swanzy (2020) a utilizat un model de mediere paralelă pentru a explora efectele sprijinului din partea supervisorilor asupra stării de bine psihologice a angajaților, prin conflictele muncă-familie și satisfacția la locul de muncă.

În schimb, medierea secvențială, cunoscută și sub denumirea de mediere serială, implică mai mulți mediatori care formează un lanț secvențial de relații cauzale între variabila predictor și variabila de rezultat. În acest model, fiecare mediator influențează următorul mediator, creând un efect indirect în cascadă. Această abordare este aplicabilă atunci când se dorește explorarea unei serii de evenimente sau procese care se desfășoară succesiv, de la variabila predictor la variabila de rezultat (Charalambous et al., 2019).

De exemplu, în domeniul asistenței sociale, un model de mediere secvențială ar putea explora modul în care accesul la sprijin social influențează calitatea vieții prin intermediul reducerii stresului și creșterii stimei de sine. În acest caz, stresul ar reprezenta primul mediator, influențând stima de sine, care la rândul său afectează calitatea vieții. Studiul lui Bharadwaj, Khan și Yameen (2022) prezintă o aplicație practică a medierii secvențiale în analiza brandingului organizațional, satisfacției în muncă și retenției angajaților, ilustrând astfel relații cauzale complexe în mediul organizațional.

Metodologic, modelele de mediere paralelă și secvențială necesită o atenție sporită în interpretarea efectelor indirecte, deoarece influențele fiecărui mediator trebuie analizate atât individual, cât și în contextul întregului model (Agler & De Boeck, 2017). Analiza mediatoarelor multiple este o tehnică esențială pentru studiile care explorează relații complexe, deoarece furnizează o înțelegere detaliată a modului în care factorii multipli interacționează pentru a influența un rezultat.

Modelele de mediere paralelă și secvențială extind analiza de mediere simplă pentru a captura procese mai complexe care implică mai mulți mediatori. Aceste modele permit evaluarea modului în care variabila independentă (X) influențează variabila dependentă (Y) prin intermediul mai multor variabile de mediere (M_1, M_2, \dots), fie în mod independent (mediere paralelă), fie într-o succesiune cauzală (mediere secvențială sau serială). Această abordare este esențială pentru înțelegerea mai detaliată a relațiilor complexe dintre variabile în cercetările din psihologie, educație și asistență socială.

Medierea paralelă implică mai mulți mediatori care acționează simultan și independent, fiecare contribuind separat la efectul indirect al variabilei independente asupra variabilei dependente. În acest model, nu există o relație cauzală între mediatori; fiecare mediator are o cale distinctă și independentă prin care influențează variabila dependentă (Kane & Ashbaugh, 2017). În consecință, efectul indirect total al lui X asupra lui Y este suma efectelor indirecte individuale ale fiecărui mediator.

Modelul de mediere paralelă poate fi reprezentat prin următoarea ecuație:

$$Y = c'X + b_1M_1 + b_2M_2 + \dots + b_nM_n + \epsilon_Y$$

unde:

- c' este coeficientul efectului direct al lui X asupra lui Y ,
- b_i sunt coeficienții pentru efectul fiecărui mediator M_i asupra lui Y , controlând pentru X și ceilalți mediatori,
- ϵ_Y este eroarea reziduală.

Astfel, efectul indirect al fiecărui mediator este calculat prin produsul coeficientului a_i (efectul lui X asupra M_i) și coeficientului b_i (efectul lui M_i asupra lui Y):

$$\text{Efect indirect (pentru } M_i) = a_i \cdot b_i$$

Efectul indirect total este suma acestor produse:

$$\text{Efect indirect total} = \sum_{i=1}^n (a_i \cdot b_i)$$

Un exemplu aplicativ în asistența socială ar putea fi modelul în care suportul social (X) influențează sănătatea mintală (Y) prin intermediul a doi mediatori independenți, cum ar fi stima de sine (M_1) și nivelul de stres (M_2). În acest caz, suportul social ar avea căi de influență indirecte prin fiecare mediator asupra sănătății mintale, iar analiza ar permite separarea efectului fiecărui mediator. Swanzy (2020) a utilizat un astfel de model pentru a explora efectele sprijinului supervisorilor asupra stării de bine a angajaților, luând în considerare conflictele muncă-familie și satisfacția la locul de muncă ca mediatori paraleli.

Medierea secvențială (sau serială) implică mai mulți mediatori care funcționează într-un lanț causal, fiecare influențând mediatorul următor într-o secvență stabilită. Aceasta creează un efect indirect în cascadă de la variabila independentă (X) către variabila dependentă (Y) printr-o serie de etape intermediare. În acest model, efectul lui X asupra lui Y trece prin fiecare mediator în ordine, rezultând o relație secvențială între variabile (Charalambous et al., 2019).

Modelul de mediere secvențială este descris de ecuații precum:

$$M_1 = a_1X + \epsilon_{M_1}$$

$$M_2 = a_2M_1 + \epsilon_{M_2}$$

$$Y = b_2M_2 + c'X + \epsilon_Y$$

unde fiecare coeficient reprezintă o relație causală specifică între variabilele adiacente în lanț. Efectul indirect total al lui X asupra lui Y prin această secvență de mediatori este produsul tuturor coeficienților implicați în lanț:

$$\text{Efect indirect secvențial} = a_1 \cdot a_2 \cdot b_2$$

Un exemplu din asistența socială ar putea implica modul în care accesul la sprijin social (X) influențează calitatea vieții (Y) printr-un proces secvențial care include reducerea stresului (M_1) și creșterea stimei de sine (M_2). În acest caz, sprijinul social reduce mai întâi stresul, care apoi crește stima de sine, iar stima de sine ridicată contribuie la o mai bună calitate a vieții (Bharadwaj, Khan & Yameen, 2022). Această abordare secvențială ajută

la explorarea modului în care procesele complexe afectează rezultatele finale în lanțuri de relații.

În interpretarea modelelor de mediere paralelă și secvențială, este important să se țină cont de influența fiecărui mediator atât individual, cât și în contextul modelului complet. Metodologic, modelele de mediere paralelă și secvențială sunt mai complexe decât medierea simplă, necesitând metode statistice mai sofisticate pentru a evalua semnificația fiecărui efect indirect (Agler & De Boeck, 2017).

Bootstrap-ul este o metodă frecvent utilizată pentru a estima intervalele de încredere ale efectelor indirecte individuale și totale, asigurând astfel robustețea estimărilor. În plus, modelele complexe necesită o verificare atentă a asumpțiilor statistice, cum ar fi liniaritatea și independența erorilor, pentru a asigura validitatea interpretărilor.

Analiza de mediere paralelă este esențială pentru studiile care explorează efectele multiple și independente ale unor variabile asupra unui rezultat, permițând evaluarea contribuțiilor unice ale fiecărui mediator. În schimb, modelul de mediere secvențială este potrivit pentru studiile care urmăresc să surprindă un proces pe etape între predictor și rezultat, oferind o înțelegere detaliată a modului în care o variabilă influențează alta printr-un lanț de factori intermediari.

În concluzie, modelele de mediere paralelă și secvențială permit o analiză detaliată a relațiilor complexe, oferind cercetătorilor un cadru robust pentru a explora mecanismele subtile și cauzalitatea indirectă în diverse domenii, de la psihologie și educație până la asistență socială.

CAPITOLUL 6.

Medierea moderată: concepte și aplicabilitate

În analiza relațiilor complexe dintre variabile, medierea moderată a devenit o metodă avansată, oferind posibilitatea de a examina nu doar relațiile directe și indirecte, dar și modul în care acestea sunt condiționate de alți factori contextuali. Medierea moderată combină două modele de analiză bine-cunoscute în științele sociale și comportamentale: modelul de mediere (care explică efectele indirecte prin variabile intermediare) și modelul de moderare (care explorează condițiile sub care relația dintre două variabile poate varia). Acest tip de analiză permite, astfel, o înțelegere mai completă a modului în care fenomenele complexe pot fi influențate simultan de variabile mediatore și moderatoare (Hayes, 2009; Rucker et al., 2011).

Din punct de vedere statistic, medierea moderată implică un model în care o variabilă independentă influențează o variabilă dependentă atât direct, cât și indirect, prin intermediul unui mediator, în timp ce acest efect indirect este influențat de o variabilă moderator. Cu alte cuvinte, puterea sau direcția efectului indirect este condiționată de nivelul moderatorului. Modelul de mediere moderată oferă o perspectivă dinamică asupra relațiilor dintre variabile, abordând variabilitatea care poate apărea în funcție de factorii contextuali (MacKinnon, 2012; Hayes & Preacher, 2014).

În cercetările psihologice și educaționale, utilizarea medierii moderate permite o analiză detaliată a relațiilor de influență, evidențiind condițiile în care efectele unui predictor asupra unui rezultat sunt maxime sau minime. De exemplu, într-o analiză a efectului sprijinului social asupra sănătății mintale, variabile precum stima de sine sau nivelul de anxietate pot fi considerate mediatori, în timp ce variabile contextuale, precum intensitatea sprijinului primit sau factorii de mediu, pot acționa ca moderatori (Bunford et al., 2015). În acest fel, medierea moderată contribuie la o înțelegere mai nuanțată a efectelor variabilelor psihosociale, ajutând la identificarea condițiilor optime pentru obținerea rezultatelor dorite.

6.1. Definirea și utilizarea modelelor de mediere moderată

Medierea moderată reprezintă o tehnică avansată de analiză statistică prin care se pot investiga nu doar efectele indirecte ale unei variabile independente asupra unei variabile dependente, ci și modul în care aceste efecte sunt condiționate de prezența unei variabile de moderare. Medierea moderată integrează elementele de bază ale medierii și moderării într-un singur model, aducând o înțelegere mai nuanțată asupra relațiilor complexe dintre variabilele analizate. Această metodă permite cercetătorilor să vadă dacă efectul indirect al variabilei independente (X) asupra variabilei dependente (Y), prin intermediul mediatorului (M), este modificat în funcție de nivelurile variabilei de moderare (W) (Rad & Demeter, 2020).

Un model de mediere moderată poate fi formalizat prin ecuații de regresie multiple, care includ interacțiuni între mediator și moderator pentru a captura efectele indirecte condiționate. Formula generală pentru medierea moderată este:

$$Y=c'X+bM+cM\cdot W+\epsilon$$

unde:

- Y este variabila dependentă,
- X este variabila independentă,
- M este variabila mediator,
- W este variabila moderator,
- c' reprezintă coeficientul efectului direct al variabilei independente asupra variabilei dependente (cu ajustarea pentru efectele mediatorului și moderatorului),
- b este coeficientul asociat relației dintre mediator și variabila dependentă,
- c este coeficientul interacțiunii între mediator și moderator,
- ϵ reprezintă termenul de eroare reziduală.

Această formulă oferă posibilitatea de a calcula efectele condiționate și interacțiunile complexe între variabile, având în vedere că influența lui M asupra lui Y poate varia în funcție de valorile lui W . Astfel, modelele de mediere moderată sunt mai potrivite pentru a surprinde nuanțele relațiilor indirecte decât un model de mediere simplă.

Coeficienții de regresie din modelele de mediere moderată permit interpretarea efectelor directe, indirecte și condiționate ale variabilelor analizate. Coeficientul c' reprezintă efectul direct al variabilei independente X asupra variabilei dependente Y , în timp ce coeficientul b indică relația dintre mediator M și variabila dependentă Y . Coeficientul c , care reprezintă interacțiunea dintre mediator și moderator, permite investigarea modului în care efectul lui M asupra lui Y variază în funcție de nivelurile lui W .

Într-o mediere moderată, dacă coeficientul de interacțiune c este semnificativ, înseamnă că efectul indirect variază în funcție de nivelul variabilei moderator. Aceasta arată că relația dintre X și Y este condiționată de prezența sau intensitatea variabilei de moderare. Pentru a testa semnificația coeficienților și a efectelor indirecte condiționate, cercetătorii folosesc de obicei metode de bootstrap, care oferă intervale de încredere pentru efectele estimate și reduc riscul erorilor de eșantionare (Hayes & Preacher, 2014).

În domeniul psihologiei, medierea moderată permite examinarea unor relații complexe între variabile psihosociale. De exemplu, în studiul realizat de Bunford și colaboratorii (2015), un model de mediere moderată a fost utilizat pentru a analiza influența disfuncțiilor emoționale asupra abilităților sociale la tinerii cu ADHD, având depresia ca variabilă moderator. În acest context, variabila ADHD este variabila independentă, abilitățile sociale sunt variabila dependentă, disfuncțiile emoționale sunt mediatorul, iar depresia acționează ca moderator. Rezultatele arată că efectul indirect al ADHD asupra abilităților sociale, prin disfuncții emoționale, este mai accentuat la tinerii care prezintă un nivel ridicat de depresie. Aceasta oferă informații prețioase pentru intervenții psihologice adaptate la condițiile individuale ale pacienților.

În educație, medierea moderată poate ajuta la identificarea factorilor care influențează performanțele elevilor, luând în considerare variabile contextuale precum sprijinul din partea profesorilor sau nivelul de autoeficacitate. Un exemplu relevant este modelul propus de Dicke și colegii (2014), care explorează modul în care autoeficacitatea în managementul clasei influențează epuizarea emoțională a profesorilor. În acest model, autoeficacitatea este variabila mediatore, epuizarea emoțională este variabila dependentă, iar problemele de disciplină din clasă acționează ca moderator. Rezultatele indică faptul că relația dintre autoeficacitate și epuizare este

condiționată de nivelul problemelor de disciplină, sugerând că profesorii cu o autoeficacitate scăzută sunt mai vulnerabili la epuizare atunci când se confruntă cu clase dificile.

În asistența socială, modelele de mediere moderată sunt folosite pentru a investiga modul în care sprijinul social afectează starea de bine a indivizilor, în funcție de factori contextuali cum ar fi nivelul de stres. Einarsen și colaboratorii (2018) au aplicat un model de mediere moderată pentru a analiza modul în care expunerea la intimidare la locul de muncă influențează implicarea angajaților, având climatul de management al conflictelor ca moderator. Rezultatele arată că efectul expunerii la intimidare asupra implicării este semnificativ mai redus în organizațiile cu un climat de susținere pentru managementul conflictelor. Aceste rezultate sugerează că sprijinul organizațional poate juca un rol crucial în menținerea angajamentului angajaților și în reducerea efectelor negative ale intimidării.

Pe lângă definirea și aplicarea conceptului de mediere moderată, implementarea practică a acestei metode implică și aspecte tehnice esențiale, cum ar fi:

- Colinearitatea între variabilele predictoare: Mediarea moderată necesită o evaluare riguroasă a colinearității între variabilele predictive și mediator. Colinearitatea ridicată poate afecta stabilitatea coeficienților de regresie și poate introduce erori în estimarea efectelor indirecte și condiționate.
- Bootstrap pentru estimarea intervalelor de încredere: Întrucât mediarea moderată poate genera erori mari de estimare, utilizarea procedurilor de bootstrap pentru obținerea intervalelor de încredere este recomandată, reducând astfel riscul de erori de eșantionare și oferind o imagine mai precisă asupra efectelor indirecte (Hayes & Preacher, 2014).
- Interpretarea interacțiunilor: Modelul de mediere moderată necesită interpretarea atentă a coeficienților de interacțiune, deoarece aceștia determină dacă efectul indirect este condiționat de nivelurile variabilei moderator. Interpretarea trebuie realizată în funcție de domeniul cercetat, pentru a identifica posibilele aplicații și implicații practice.

În concluzie, modelele de mediere moderată oferă un cadru analitic puternic pentru a analiza relațiile indirecte și condiționate dintre variabile. Aplicarea acestora în psihologie, educație și asistență socială poate dezvălui

detalii importante despre modul în care factorii psihosociali, educaționali și organizaționali interacționează în contexte complexe.

6.2. Identificarea și interpretarea interacțiunilor dintre variabile

Un element esențial al medierii moderate constă în capacitatea de a identifica și interpreta interacțiunile dintre variabile, în special între mediator și moderator. Interacțiunile reprezintă modul în care influența unui mediator asupra relației dintre variabila independentă și cea dependentă variază în funcție de nivelurile unei variabile de moderare. Coeficientul de interacțiune, adesea notat prin c în modelele statistice, indică măsura în care efectul indirect al variabilei independente asupra variabilei dependente este condiționat de nivelul moderatorului. Acest coeficient evidențiază circumstanțele în care o variabilă mediatoare este mai puternic sau mai slab asociată cu variabila dependentă, oferind astfel o înțelegere mai detaliată a condițiilor de influență (Hayes & Preacher, 2014).

În cadrul analizei statistice, medierea moderată este adesea calculată folosind modelul 8 din macro-ul PROCESS dezvoltat de Andrew F. Hayes. Acest model facilitează evaluarea interacțiunilor complexe dintre mediator și moderator și permite o abordare sistematică a estimării efectelor indirecte condiționate.

Formulele care descriu medierea moderată includ coeficienții de interacțiune care ajustează efectul indirect al variabilei independente (X) asupra variabilei dependente (Y) în funcție de nivelurile variabilei moderator (W). Un efect indirect condiționat poate fi exprimat astfel:

$$\text{Efect indirect condiționat} = (a+b \cdot W) \cdot M$$

unde: a și b sunt coeficienții asociați relației dintre mediator (M) și variabila independentă (X), W este variabila de moderare, M este mediatorul.

Această formulă explică modul în care un efect indirect se poate modifica în funcție de nivelul variabilei de moderare W , oferind o perspectivă dinamică asupra modului în care factorii contextuali influențează relațiile indirecte.

De exemplu, în studiul lui Andreeva și Kianto (2011), s-a folosit un model de mediere moderată pentru a examina modul în care procesele de cunoaștere și inovație sunt condiționate de intensitatea cunoașterii organizaționale. Modelul a permis cercetătorilor să determine că efectul inovării asupra performanței organizaționale este mai pronunțat în organizațiile cu un nivel ridicat de cunoaștere organizațională. Astfel, coeficientul de interacțiune între mediator (cunoașterea organizațională) și moderator (intensitatea cunoașterii) a ilustrat o relație mai complexă, evidențiind cum anumite condiții organizaționale pot amplifica sau atenua influența proceselor de cunoaștere asupra inovării.

Interpretarea coeficienților de interacțiune într-un model de mediere moderată necesită o analiză atentă a efectelor condiționate. În funcție de semnificația statistică a coeficientului de interacțiune, cercetătorii pot determina dacă efectul indirect este influențat de moderator. Dacă acest coeficient este semnificativ, relația dintre variabilele independentă și dependentă, prin mediator, depinde de nivelul variabilei moderator (Rucker et al., 2011).

În psihologie, identificarea interacțiunilor dintre variabile este crucială pentru a înțelege modurile complexe în care factorii psihosociali influențează comportamentul. De exemplu, Chughtai și Khan (2024) au folosit medierea moderată pentru a examina relația dintre leadership-ul orientat spre cunoaștere și performanța inovatoare a angajaților. În acest caz, satisfacția la locul de muncă a acționat ca mediator între sprijinul de la lideri și performanța inovatoare, iar orientarea liderului spre cunoaștere a moderat această relație. Acest model a permis identificarea unor condiții optime în care efectul sprijinului de la lideri asupra performanței inovatoare este maxim, contribuind la strategii eficiente de management organizațional.

În educație, modelele de mediere moderată pot evidenția modul în care factori contextuali, precum sprijinul familial sau școlar, influențează performanțele academice ale elevilor prin intermediul variabilelor psihologice (ex. motivația sau autoeficacitatea). Dicke și colaboratorii (2014) au folosit un astfel de model pentru a studia modul în care autoeficacitatea profesorilor în managementul clasei este condiționată de problemele de disciplină din clasă. În acest caz, autoeficacitatea profesorilor a acționat ca mediator între sprijinul educațional și epuizarea emoțională, în timp ce nivelul problemelor de disciplină a moderat această relație. Rezultatele au

arătat că, la un nivel ridicat al problemelor de disciplină, epuizarea emoțională a fost mai puternică în rândul profesorilor cu o autoeficacitate scăzută.

În domeniul asistenței sociale, modelele de mediere moderată ajută la identificarea factorilor care influențează starea de bine a indivizilor în situații de vulnerabilitate. Einarsen și colegii (2018) au investigat rolul sprijinului organizațional în relația dintre intimidare la locul de muncă și implicarea angajaților. Mediatorul a fost implicarea angajaților, iar climatul organizațional pentru gestionarea conflictelor a fost moderatorul. Modelul a arătat că efectul negativ al intimidării asupra implicării angajaților a fost mai redus în organizațiile cu un climat pozitiv de gestionare a conflictelor.

În modelele de mediere moderată, metodele de bootstrap sunt esențiale pentru obținerea unor intervale de încredere robuste pentru efectele indirecte condiționate. Aceste metode, recomandate de Hayes și Preacher (2014), sunt deosebit de utile atunci când datele nu respectă distribuțiile normale, ceea ce face dificilă aplicarea metodelor de testare parametrică. Metoda de bootstrap creează eșantioane multiple din setul de date original și calculează estimări ale coeficienților și intervalelor de încredere pe baza acestor eșantioane, oferind o interpretare mai precisă a efectelor indirecte condiționate.

Pentru a ilustra, un efect indirect condiționat poate fi reprezentat prin formula:

$$\text{Efect indirect condiționat} = (a + b \cdot W) \cdot M$$

unde:

- a reprezintă efectul variabilei independente asupra mediatorului,
- b indică influența interacțiunii dintre mediator și moderator asupra variabilei dependente,
- W este variabila moderator,
- M este mediatorul.

Astfel, formula explică modul în care efectul variabilei independente asupra variabilei dependente prin intermediul mediatorului se modifică în funcție de nivelurile variabilei moderator. Această abordare oferă o imagine clară asupra relațiilor complexe și permite cercetătorilor să evalueze dacă și cum efectele indirecte variază în funcție de condițiile contextuale ale studiului.

Identificarea și interpretarea interacțiunilor dintre variabilele mediator și moderator sunt fundamentale pentru analiza de mediere moderată. Utilizarea coeficienților de interacțiune și a metodelor de bootstrap permite o abordare riguroasă, oferind perspective detaliate asupra modului în care efectele indirecte sunt influențate de condiții contextuale specifice. În diverse domenii, de la psihologie la educație și asistență socială, modelele de mediere moderată contribuie la o înțelegere avansată a relațiilor indirecte condiționate, ajutând astfel la dezvoltarea intervențiilor și politicilor bazate pe dovezi.

6.3. Aplicații ale medierii moderate în științele sociale și implicațiile rezultatelor

Medierea moderată reprezintă o metodă analitică puternică și versatilă, aplicabilă în diverse domenii ale științelor sociale, precum psihologia, educația și asistența socială. Aceasta permite cercetătorilor să exploreze mecanismele complexe prin care diferiți factori contextuali, ce acționează ca moderatori, influențează procesele de mediere. În acest mod, medierea moderată deschide noi perspective asupra modului în care variabilele psihosociale, de suport sau cele contextuale modelează relațiile dintre variabilele independente și dependente.

Un domeniu central de aplicare a medierii moderate este psihologia, unde este utilizată pentru a investiga modul în care factori contextuali influențează starea de bine sau sănătatea mintală a indivizilor. În studiul lui Jokić și colegii (2024), medierea moderată a fost folosită pentru a examina relația dintre timpul petrecut utilizând tehnologia digitală, singurătatea și bunăstarea generală la adolescenți. Modelul a demonstrat că efectul mediat al timpului petrecut pe tehnologie asupra bunăstării generale este condiționat de nivelul de singurătate experimentat. Mai exact, s-a observat că, pentru adolescenții cu un nivel ridicat de singurătate, timpul petrecut pe tehnologie are un impact negativ asupra bunăstării, pe când, la niveluri mai scăzute ale singurătății, acest efect este mai redus sau chiar inexistent. Această utilizare a medierii moderate evidențiază importanța factorilor contextuali în cercetările de sănătate mintală și oferă indicații pentru intervențiile psihologice țintite, adresate nevoilor specifice ale adolescenților care se confruntă cu singurătatea.

În analiza statistică, medierea moderată în acest caz poate fi reprezentată prin următoarea formulă de efect indirect condiționat:

$$\text{Efect indirect condiționat}=(a+b\cdot W)\cdot M$$

unde:

- a reprezintă influența inițială a variabilei independente (timpul pe tehnologie) asupra mediatorului (bunăstarea),
- b este coeficientul care măsoară modul în care interacțiunea dintre mediator și moderator (singurătatea) afectează variabila dependentă (bunăstarea generală),
- W reprezintă nivelul variabilei moderator, iar
- M este mediatorul.

În domeniul educației, modelele de mediere moderată sunt utilizate pentru a identifica factorii care contribuie la performanța profesorilor și la bunăstarea acestora, luând în considerare variabile contextuale, precum problemele de disciplină din clasă. Studiul realizat de Dicke și colaboratorii (2014) ilustrează această metodă prin explorarea modului în care autoeficacitatea profesorilor în gestionarea clasei este influențată de nivelul de disciplină din clasă. În acest model, autoeficacitatea profesorilor acționează ca mediator între sprijinul din partea școlii și performanța acestora, iar nivelul problemelor de disciplină funcționează ca un moderator.

Modelul relevă că efectul pozitiv al autoeficacității asupra performanței cadrelor didactice este amplificat în clasele cu o disciplină mai puțin problematică. Aceasta sugerează că profesorii se simt mai eficienți și sunt mai performanți în contexte educaționale unde problemele de disciplină sunt mai reduse. Aceste rezultate au implicații directe pentru dezvoltarea programelor de formare a cadrelor didactice, subliniind importanța susținerii profesorilor în dezvoltarea abilităților de management al clasei și alocarea resurselor în clasele cu probleme de disciplină ridicată.

În modelul de mediere moderată, estimarea efectelor indirecte condiționate poate fi realizată cu ajutorul metodei de bootstrap, care permite obținerea unor intervale de încredere mai precise pentru coeficienții de interacțiune. Această metodă, recomandată de Hayes și Preacher (2014), este utilizată pentru a testa semnificația statistică a efectului indirect condiționat, ceea ce permite o interpretare riguroasă a modului în care mediatorul și

moderatorul interacționează în model. Pentru a evalua fiabilitatea acestui model, se generează mii de eșantioane replicate, oferind o bază statistică solidă pentru interpretarea efectelor condiționate.

În cadrul organizațiilor și al asistenței sociale, medierea moderată joacă un rol important în evaluarea impactului climatului organizațional asupra implicării și satisfacției angajaților. Einarsen și colegii (2018) au utilizat un model de mediere moderată pentru a analiza relația dintre intimidarea la locul de muncă, sprijinul organizațional și implicarea angajaților. În acest model, expunerea la intimidare este variabila independentă, implicarea angajaților acționează ca variabilă dependentă, iar climatul organizațional pentru gestionarea conflictelor joacă rolul de moderator.

Rezultatele studiului au arătat că implicarea angajaților este afectată indirect de nivelul de intimidare la locul de muncă, dar efectul negativ al intimidării este diminuat în organizațiile cu un climat pozitiv de gestionare a conflictelor. Astfel, sprijinul pentru gestionarea conflictelor poate reduce efectul advers al intimidării asupra implicării angajaților, promovând un mediu de lucru mai sănătos și mai eficient.

Modelele de mediere moderată oferă o perspectivă valoroasă asupra dinamicii organizaționale și ajută la dezvoltarea unor strategii eficiente de management. Rezultatele obținute din analizele de mediere moderată permit managerilor și factorilor decizionali să înțeleagă mai bine rolul contextului organizațional și al suportului în modelarea comportamentului angajaților și în îmbunătățirea performanței acestora. De asemenea, în asistența socială, aceste modele pot informa strategii de intervenție, evidențiind importanța sprijinului social în relația dintre stresul la locul de muncă și bunăstarea psihologică a indivizilor.

Astfel, medierea moderată reprezintă o abordare metodologică avansată care îmbogățește înțelegerea relațiilor indirecte condiționate, facilitând descoperirea unor mecanisme complexe de influență în diverse domenii ale științelor sociale. De la psihologie și educație până la management organizațional și asistență socială, medierea moderată oferă o perspectivă detaliată asupra modului în care factori contextuali și psihosociale influențează comportamentele și rezultatele. Aceste modele permit o interpretare statistică riguroasă a interacțiunilor complexe și oferă o bază solidă pentru dezvoltarea de politici și intervenții care răspund nevoilor specifice ale grupurilor țintă.

CAPITOLUL 7.

Instrumente și software pentru analiza statistică

Acest capitol oferă o prezentare detaliată a principalelor software-uri utilizate pentru analiza statistică în cercetare: SPSS, JASP și JAMOVI. Aceste instrumente sunt esențiale pentru efectuarea analizelor corelaționale, regresiiilor, precum și pentru analizele de mediere și moderare. De asemenea, vom explora avantajele fiecărui software, costurile și cerințele de instalare, dar și instrucțiuni de utilizare pentru a facilita aplicarea lor în cercetarea empirică.

7.1. Prezentarea principalelor software-uri: SPSS, JASP, JAMOVI

SPSS (Statistical Package for the Social Sciences)

SPSS este unul dintre cele mai cunoscute software-uri pentru analiza statistică, utilizat în mod extensiv în domenii precum științele sociale, educația și psihologia. Acest software a fost dezvoltat de IBM și oferă o gamă largă de instrumente statistice, incluzând analize corelaționale, regresii, modele de mediere și moderare. Cu o interfață intuitivă și o puternică funcționalitate, SPSS este o alegere preferată de cercetători pentru complexitatea analitică și flexibilitatea sa.

SPSS este un software comercial, iar prețul variază în funcție de pachet și tipul de licență. Licențele pot fi achiziționate fie lunar, fie anual, iar prețul de pornire pentru o licență de bază este de aproximativ 99 USD pe lună. În funcție de tipul de licență și de setul de module achiziționate, costul poate crește. Universitățile oferă adesea acces gratuit pentru studenți și cadre didactice, permițându-le acestora să acceseze funcționalitățile SPSS pentru proiecte de cercetare academice. Pentru informații suplimentare și achiziționarea licențelor, consultați IBM SPSS Pricing.

Instalarea SPSS necesită următorii pași:

- Vizitați site-ul oficial al IBM SPSS și creați un cont IBM.
- Descărcați versiunea potrivită pentru sistemul de operare (Windows sau MacOS) și urmați instrucțiunile de instalare. Pentru funcționalitatea completă, introduceți cheia de licență primită la achiziționarea licenței.
- Cerințe de sistem: SPSS este compatibil cu sistemele Windows (minim Windows 10) și MacOS (minim MacOS Mojave), iar pentru o performanță optimă, este recomandat un spațiu minim de 4GB RAM.

JASP

JASP este o platformă gratuită și open-source de analiză statistică, destinată cercetătorilor care preferă un software intuitiv și accesibil. JASP combină simplitatea utilizării cu o performanță solidă, fiind deosebit de popular pentru analizele bayesiene, dar oferind și funcționalități robuste pentru analiza frecventistă. Interfața sa este similară cu cea a SPSS, ceea ce îl face ideal pentru cercetători care doresc un software ușor de navigat, dar fără costuri asociate.

JASP este complet gratuit și open-source, fiind dezvoltat de cercetători pentru cercetători. Software-ul poate fi descărcat direct de pe site-ul oficial JASP, fără necesitatea unei licențe sau a unei plăți.

Instalare:

- Vizitați pagina oficială JASP și descărcați versiunea compatibilă cu sistemul dumneavoastră.
- JASP funcționează pe sistemele Windows (minim Windows 7), MacOS (minim MacOS Mojave) și Linux.
- După descărcare, urmați pașii simpli de instalare descriși pe ecran.
- JASP oferă funcționalități pentru analize corelaționale, regresii, medieri, inclusiv analize bayesiene, și produce rapoarte clare și concise. Modulul de bayesiană este un avantaj unic al acestui software și îi conferă flexibilitate în raport cu alte platforme.

JAMOVI

JAMOVI este un alt software gratuit și open-source, dezvoltat pe baza limbajului de programare R și conceput să fie accesibil pentru utilizatorii non-tehnici. Spre deosebire de SPSS, JAMOVI nu necesită licențe și poate fi instalat rapid, fiind extrem de popular printre cercetătorii din domeniile sociale, educaționale și psihologice.

Complet gratuit și open-source, JAMOVI poate fi descărcat de pe site-ul oficial JAMOVI.

Instalare:

- Descărcați instalatorul de pe pagina JAMOVI și urmați pașii de instalare.
- Cerințe de sistem: JAMOVI este compatibil cu Windows (minim Windows 7), MacOS și Linux.
- JAMOVI permite analize de bază și avansate, incluzând corelații, regresii și medieri. Pe lângă modulele de bază, biblioteca JAMOVI include module adiționale care pot fi instalate pentru a extinde funcționalitatea software-ului..

7.2. Tutoriale aplicative pentru analize corelaționale și de regresie

Analiza corelațională în SPSS

Pentru a efectua o analiză corelațională în SPSS, urmați acești pași în detaliu:

1. **Importul datelor:** Deschideți SPSS și navigați către *File > Open > Data* pentru a deschide setul de date dorit. Acest lucru vă permite să încărcați un fișier de tip .sav (format specific SPSS), în care datele au fost deja organizate în variabile și observații. Odată ce ați selectat fișierul și ați făcut clic pe „*Open*”, datele vor apărea în fereastra principală de editare a datelor din SPSS.
2. **Selectarea analizei corelaționale:** În meniul principal, accesați *Analyze > Correlate > Bivariate....* Această opțiune deschide fereastra de configurare a corelațiilor bivariate, unde veți putea selecta

variabilele și specifica tipul de analiză corelațională pe care doriți să o efectuați.

3. **Selectarea variabilelor:** În fereastra „*Bivariate Correlations*” care se deschide, identificați variabilele din lista din stânga și selectați-le pe cele pe care doriți să le corelați. După ce ați selectat variabilele, utilizați săgeata pentru a le muta în câmpul „*Variables*” din dreapta. Asigurați-vă că variabilele pe care le selectați sunt de tip numeric, deoarece SPSS va calcula corelațiile doar între variabile numerice.

4. **Setarea tipului de corelație:** În fereastra de configurare, veți găsi opțiuni pentru tipul de corelație pe care doriți să îl aplicați. SPSS oferă trei tipuri principale de corelații:

- **Pearson:** Corelația liniară, potrivită pentru variabile de interval sau raport și pentru relații liniare.
- **Spearman:** Corelația pe bază de ranguri, potrivită pentru date ordinale sau pentru relații monotone.
- **Kendall:** Corelația tau, o altă metodă bazată pe ranguri, folosită în mod special pentru seturi de date mai mici sau cu multe legături.

Bifați caseta corespunzătoare pentru tipul de corelație pe care doriți să îl calculați, în funcție de caracteristicile datelor și scopul analizei.

5. **Selectarea opțiunilor suplimentare:** SPSS oferă și alte setări care pot fi utile în analiza corelațională. De exemplu:

- **Two-tailed sau One-tailed:** Alegeți Two-tailed dacă nu aveți o ipoteză specifică privind direcția relației sau One-tailed dacă anticipați că relația este pozitivă sau negativă.
- **Flag significant correlations:** Aceasta opțiune evidențiază corelațiile care ating un nivel de semnificație statistică. Bifând această casetă, SPSS va marca automat corelațiile semnificative cu un asterisc în raportul de Output.

6. **Executarea analizei:** După ce ați configurat toate opțiunile, faceți clic pe butonul *OK* pentru a rula analiza corelațională. SPSS va calcula coeficienții de corelație pentru variabilele selectate și va afișa rezultatele în fereastra de *Output*. Raportul va conține matricea corelațiilor, unde fiecare celulă arată coeficientul de corelație pentru

perechea respectivă de variabile, semnificația statistică și numărul de observații utilizate pentru fiecare pereche de variabile.

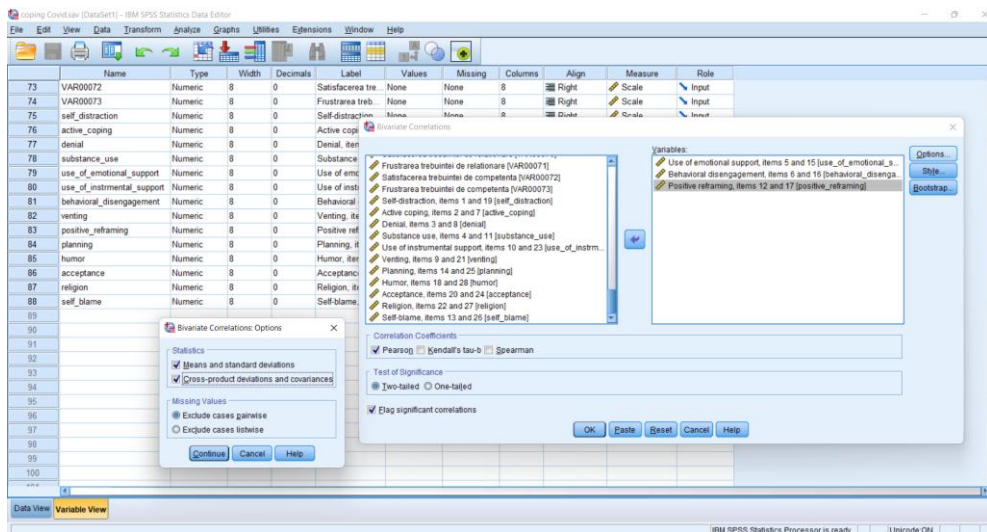


Figura 1: Setarea analizei corelaționale în SPSS

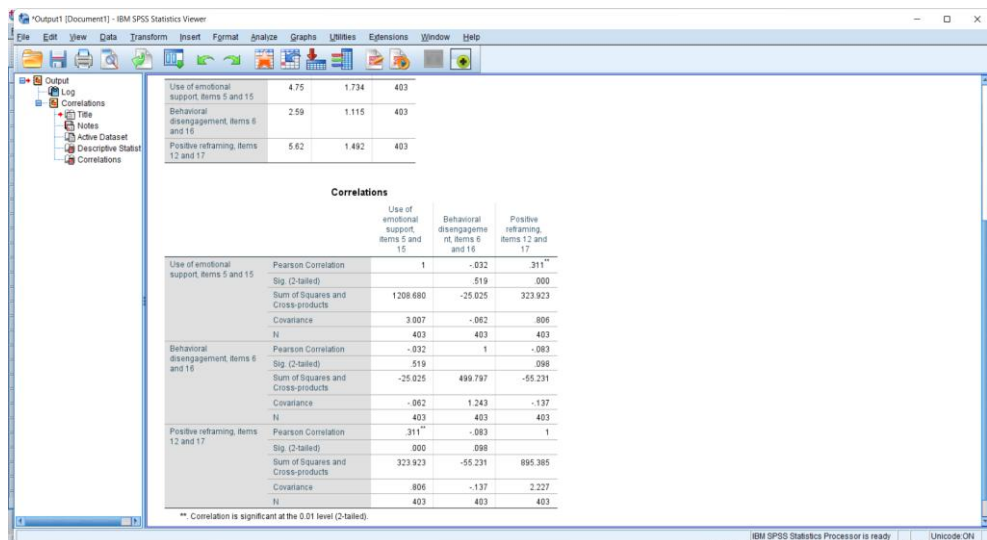


Figura 2. Output analiză corelațională în SPSS

Pentru a interpreta rezultatele analizei corelaționale din Figura 2, urmați acești pași:

1. Identificarea perechilor de variabile și interpretarea coeficienților de corelație

În matricea de corelații, fiecare celulă conține coeficientul de corelație Pearson pentru o pereche de variabile. În acest exemplu, coeficienții de corelație sunt prezentați pentru trei variabile: „Use of emotional support” (Items 5 și 15), „Behavioral disengagement” (Items 6 și 16), și „Positive reframing” (Items 12 și 17).

Coeficientul de corelație Pearson variază între -1 și +1:

- O valoare de +1 indică o corelație perfect pozitivă, ceea ce înseamnă că pe măsură ce o variabilă crește, și cealaltă crește proporțional.
- O valoare de -1 indică o corelație perfect negativă, unde o creștere a unei variabile este asociată cu o scădere a celeilalte variabile.
- O valoare de 0 sugerează că nu există nicio corelație între cele două variabile.

În Figura 2:

- Corelația între „Use of emotional support” și „Positive reframing” este **0,311**, ceea ce indică o corelație pozitivă moderată. Aceasta înseamnă că indivizii care raportează utilizarea suportului emoțional tind să aibă și scoruri mai mari pentru reframing pozitiv.
- Corelația între „Use of emotional support” și „Behavioral disengagement” este foarte mică și negativă (-0,062), ceea ce sugerează o relație slabă între aceste variabile.

2. Interpretarea semnificației statistice (p-value)

În celulele din dreapta fiecărui coeficient de corelație, este prezentată valoarea de semnificație (Sig. 2-tailed), care indică dacă relația observată este semnificativă statistic:

- O valoare a p-ului sub 0,05 sau 0,01 este considerată semnificativă, indicând că există o probabilitate scăzută ca relația observată să fie rezultatul întâmplării.

În exemplul nostru:

- Corelația dintre „Use of emotional support” și „Positive reframing” este semnificativă la nivelul de 0,01, marcată prin două asteriscuri (**). Aceasta sugerează că relația observată este semnificativă statistic.
- Corelațiile dintre „Use of emotional support” și „Behavioral disengagement” nu sunt semnificative ($p > 0,05$), ceea ce indică faptul că această relație nu este semnificativă.

3. Evaluarea direcției și a forței corelațiilor

După interpretarea valorilor coeficienților și a semnificației statistice, evaluăm dacă relațiile sunt puternice, moderate sau slabe. În exemplul nostru:

- Corelația moderată între „Use of emotional support” și „Positive reframing” sugerează o relație directă modestă, dar semnificativă între suportul emoțional și reframing-ul pozitiv.

Pași tehnici pentru interpretarea rezultatelor în SPSS:

1. **Identificați coeficientul de corelație** pentru perechea de variabile de interes și notați-l (e.g., 0,311 pentru „Use of emotional support” și „Positive reframing”).
2. **Verificați valoarea p** asociată pentru a determina semnificația statistică. În exemplul nostru, $p < 0,01$ pentru aceeași pereche de variabile, ceea ce sugerează că relația este semnificativă.
3. **Interpretați direcția și forța** relației în funcție de valoarea coeficientului și semnificația statistică, ținând cont de contextul și sensul variabilelor analizate.

Analiza de regresie liniară în SPSS

Pentru a efectua o analiză de regresie liniară simplă în SPSS și a interpreta rezultatele obținute, urmați pașii detaliați de mai jos:

1. Importul datelor

La fel ca în cazul analizei corelaționale, importul datelor este primul pas. Deschideți SPSS și încărcați setul de date dorit, accesând **File > Open > Data** și selectând fișierul cu extensia .sav care conține datele necesare.

2. Selectarea analizei de regresie liniară

Pentru a accesa opțiunea de regresie liniară simplă, navigați la **Analyze > Regression > Linear...** Această comandă deschide fereastra de configurare a analizei de regresie, unde puteți selecta variabilele și ajusta setările analizei.

3. Alegerea variabilelor

În fereastra de regresie liniară, trebuie să specificați variabila dependentă și variabila independentă:

- **Dependentă:** Selectați variabila care reprezintă rezultatul pe care doriți să-l preziceți și mutați-o în câmpul „Dependent”.
- **Independentă:** Selectați variabila predictor pe care o testați pentru a vedea dacă influențează variabila dependentă și mutați-o în câmpul „Independent(s)”.

De exemplu, dacă sunteți interesat să analizați modalitatea în care stresul (independentă) influențează performanța academică (dependentă), selectați performanța academică în câmpul „Dependent” și stresul în câmpul „Independent(s)”.

4. Opțiuni avansate

SPSS oferă opțiuni suplimentare pentru a rafina analiza de regresie:

- Accesați **Statistics...** pentru a deschide o listă de opțiuni adiționale.
 - **Descriptives:** Bifați această opțiune pentru a obține statistici descriptive pentru variabilele selectate.
 - **Confidence Intervals:** Bifați această opțiune pentru a include intervalele de încredere pentru coeficienții de regresie, care sunt utile pentru a înțelege precizia estimărilor.
 - **R Square Change** și **Durbin-Watson** sunt alte opțiuni disponibile, recomandate dacă doriți să evaluați suplimentar ajustarea modelului sau independența erorilor.

După selectarea opțiunilor dorite, faceți click pe **Continue** pentru a reveni la fereastra principală a analizei de regresie.

5. Executarea analizei

Faceți click pe **OK** pentru a rula analiza de regresie. SPSS va genera un output care include coeficienții de regresie și alte statistici relevante. Acestea vor fi afișate în fereastra de Output SPSS, iar interpretarea rezultatelor este detaliată mai jos.

Interpretarea rezultatelor analizei de regresie

a) Coeficientul de determinare R^2

- Coeficientul R^2 indică proporția varianței variabilei dependente explicată de variabila independentă. Acesta variază între 0 și 1, unde valori apropiate de 1 indică o potrivire bună a modelului, adică predictorul explică o mare parte din varianța rezultatului. De exemplu, un R^2 de 0,7 sugerează că 70% din variația în performanța academică poate fi explicată de nivelul de stres.

b) Coeficienții de regresie (β_0 și β_1)

- În tabelul **Coefficients**, veți găsi interceptul (β_0) și coeficientul de panta (β_1) pentru variabila independentă.
 - **Interceptul (β_0)** reprezintă valoarea estimată a variabilei dependente atunci când variabila independentă este 0. Deși nu are mereu o interpretare practică, acesta oferă context pentru modelul de regresie.
 - **Coeficientul de panta (β_1)** indică rata de schimbare a variabilei dependente pentru fiecare unitate de creștere în variabila independentă. Dacă panta este pozitivă, creșterea variabilei independente este asociată cu o creștere a variabilei dependente. Dacă panta este negativă, există o relație inversă.

c) Testul de semnificație pentru coeficienți (t-test)

- SPSS oferă și valoarea p (p-value) asociată fiecărui coeficient. Dacă $p < 0,05$, atunci coeficientul este semnificativ statistic, indicând o relație semnificativă între variabila independentă și cea dependentă. În outputul SPSS, coeficienții semnificativi sunt adesea evidențiați pentru o interpretare ușoară.

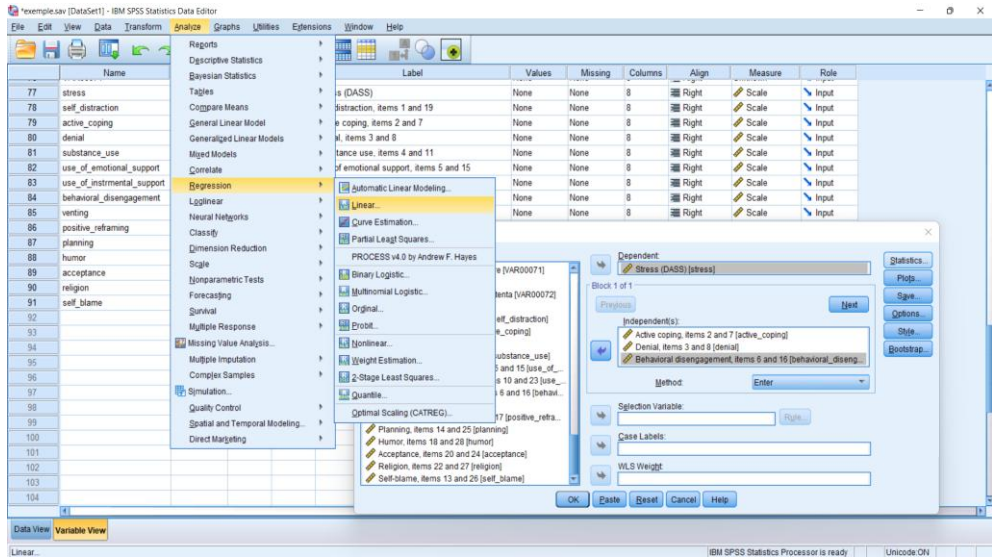


Figura 3. Structura ferestrei de regresie în SPSS.

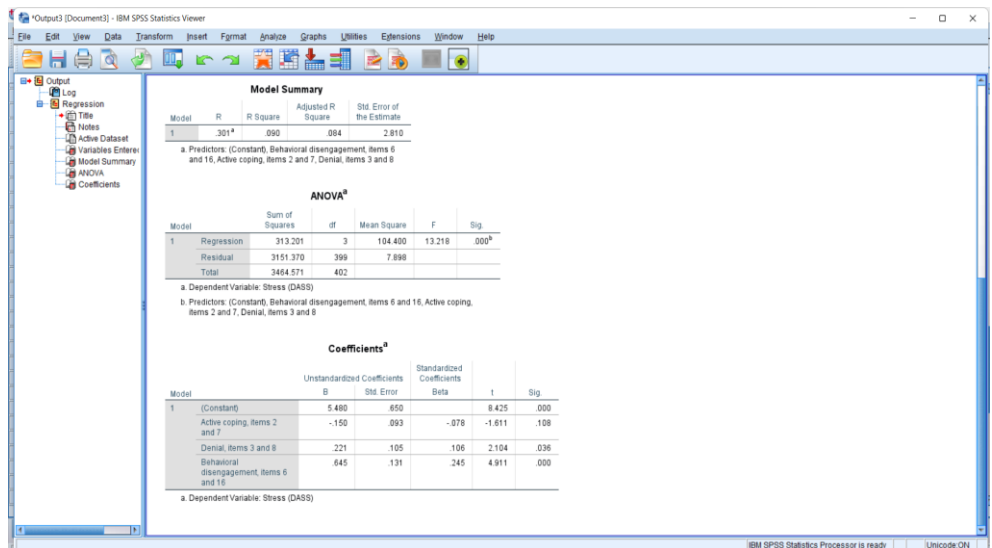


Figura 4. Output analiză de regresie în SPSS

Pentru a interpreta outputul analizei de regresie în SPSS din Figura 4, vom parcurge fiecare secțiune a outputului pentru a înțelege relațiile dintre variabilele incluse în model și semnificația acestora.

1. Model Summary

Această secțiune oferă un rezumat al performanței modelului de regresie.

- **R** este coeficientul de corelație între variabilele predictorii și variabila dependentă. În acest caz, valoarea este 0,301, ceea ce sugerează o corelație moderat scăzută între predictorii incluși și variabila dependentă.
- **R Square (R²)** indică proporția de variație din variabila dependentă explicată de variabilele independente din model. Valoarea 0,090 înseamnă că aproximativ 9% din variația în variabila dependentă („Stress - DASS”) este explicată de predictorii incluși (Active coping, Denial, și Behavioral disengagement). Aceasta sugerează că există mulți alți factori care influențează „Stress - DASS” în afara celor incluși în acest model.
- **Adjusted R Square** este o valoare ajustată a lui R², care ia în considerare numărul de predictorii din model. Aceasta este utilă mai ales atunci când se utilizează mai mulți predictorii, pentru a evita supraestimarea potrivirii modelului. În acest caz, valoarea de 0,084 este ușor mai mică decât R², ceea ce sugerează că adăugarea de predictorii nu îmbunătățește foarte mult explicarea varianței.
- **Std. Error of the Estimate** reprezintă deviația standard a rezidualelor, oferind o măsură a cât de bine se potrivesc predicțiile modelului cu valorile observate ale variabilei dependente. Valoarea de 2,810 indică abaterea medie a valorilor observate față de cele prezise.

2. ANOVA

Această secțiune evaluează semnificația generală a modelului de regresie.

- **F și Sig.:** Valoarea F (7,898) și valoarea p asociată (0,000) indică faptul că modelul de regresie este semnificativ din punct de vedere statistic la un nivel de semnificație de 0,01. Cu alte cuvinte, există o relație semnificativă între cel puțin unul dintre predictorii incluși și variabila dependentă. Aceasta înseamnă că variabilele predictorii contribuie semnificativ la explicarea varianței în „Stress - DASS”.

3. Coefficients

Această secțiune afișează coeficienții de regresie, care arată efectul fiecărei variabile independente asupra variabilei dependente, ținând cont de ceilalți predictorii.

- **Unstandardized Coefficients (B):**

- **Constant:** Interceptul (5,480) reprezintă valoarea estimată a „Stress - DASS” atunci când toți predictorii au valoarea zero.
- **Active coping:** Coeficientul (-0,150) indică faptul că, pentru fiecare unitate de creștere în „Active coping”, scorul „Stress - DASS” scade cu 0,150, sugerând o relație inversă. Totuși, valoarea p (0.108) arată că această relație nu este semnificativă la un nivel de 0,05.
- **Denial:** Coeficientul (-0,225) sugerează o relație inversă între „Denial” și „Stress - DASS”, cu o scădere de 0.225 în stres pentru fiecare unitate de creștere în „Denial”. Valoarea p (0,036) indică faptul că acest efect este semnificativ la un nivel de 0,05.
- **Behavioral disengagement:** Coeficientul (0,645) indică o relație pozitivă între „Behavioral disengagement” și „Stress - DASS”, ceea ce înseamnă că o creștere cu o unitate în „Behavioral disengagement” este asociată cu o creștere de 0,645 în scorul de stres. Valoarea p (0,000) arată că acest efect este foarte semnificativ.

- **Standardized Coefficients (Beta):**

- Aceste valori oferă o măsură a mărimii efectului fiecărui predictor în termeni standardizați, permițând comparații între efectele variabilelor independente. De exemplu, „Behavioral disengagement” are cel mai mare coeficient Beta (0,241), indicând că aceasta are cel mai puternic efect asupra „Stress - DASS” comparativ cu ceilalți predictorii din model.

- **t și Sig.:**

- Aceste valori arată rezultatele testului de semnificație pentru fiecare coeficient individual. Valorile t mari și valorile p sub 0,05 indică faptul că predictorii au un efect semnificativ asupra variabilei dependente. În acest model, doar „Denial” și „Behavioral disengagement” au coeficienți semnificativi.

Interpretarea generală a outputului

Modelul de regresie sugerează că „Behavioral disengagement” are un efect semnificativ și pozitiv asupra stresului, ceea ce înseamnă că pe măsură

ce comportamentul de dezangajare crește, crește și nivelul de stres. „Denial” are, de asemenea, un efect semnificativ, dar negativ, indicând că persoanele care folosesc negarea ca mecanism de coping pot experimenta niveluri mai scăzute de stres. „Active coping” nu are un efect semnificativ, ceea ce sugerează că acest predictor nu este un factor semnificativ în modelul curent pentru explicarea varianței în stres.

Analiza corelațională în JASP

Pentru a interpreta rezultatele analizei corelaționale în JASP, vom parcurge fiecare secțiune a outputului prezentat în Figura 5.

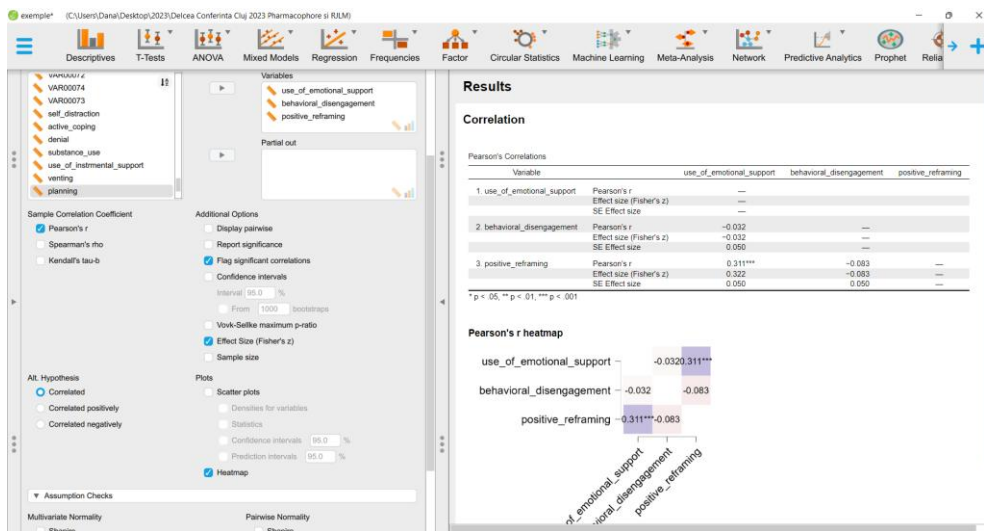


Figura 5. Setarea analizei corelaționale și Output în JASP

Pentru a realiza o analiză corelațională în JASP, se parcurg pașii de mai jos, utilizând variabilele „Use of Emotional Support,” „Behavioral Disengagement,” și „Positive Reframing” pentru a examina relațiile dintre acestea:

1. Importul datelor

Deschideți JASP și utilizați opțiunea *Open > Computer > Browse* pentru a încărca setul de date dorit. Setul de date include variabilele „Use of Emotional Support,” „Behavioral Disengagement,” și „Positive Reframing,” ce urmează a fi analizate în matricea de corelație.

2. Accesarea funcției de corelație

Navigați la meniul *Regression > Correlation Matrix*. Aceasta deschide fereastra de setări, unde se configurează parametrii analizei.

3. Selectarea variabilelor

Din lista de variabile disponibile, selectați „Use of Emotional Support,” „Behavioral Disengagement,” și „Positive Reframing” și mutați-le în zona *Variables* din fereastra de analiză. Aceste variabile vor fi incluse în matricea de corelație.

4. Selectarea coeficientului de corelație

În fereastra de setări, alegeți coeficientul dorit:

- *Pearson's r* pentru corelații parametrice ce presupun o relație liniară între variabile și o distribuție normală.
 - *Spearman's rho* sau *Kendall's tau-b* pentru date ordinale sau pentru cazurile în care condițiile de normalitate nu sunt îndeplinite.
- În exemplul nostru, am selectat coeficientul Pearson pentru a calcula corelațiile între variabile.

5. Opțiuni suplimentare

Activați *Flag significant correlations* pentru a evidenția corelațiile semnificative. De asemenea, selectați opțiunea *Heatmap* pentru a vizualiza rezultatele sub formă grafică. Nivelul de încredere pentru intervalele de încredere poate fi setat la 95%.

6. Rularea analizei

După configurarea setărilor, JASP execută analiza automat, iar rezultatele sunt afișate în fereastra principală de Output.

Interpretarea outputului

Rezultatele analizei corelaționale sunt prezentate sub forma unui tabel ce include coeficienții Pearson și semnificația statistică a relațiilor dintre variabile.

- Corelația dintre „Use of Emotional Support” și „Positive Reframing” Coeficientul de corelație este -0.311, indicând o corelație negativă moderată. Semnificația statistică este marcată cu *** ($p < 0.001$), ceea ce sugerează că această relație este semnificativă. Aceasta poate însemna că indivizii care utilizează mai mult sprijinul emoțional tind să folosească mai puțin reframing-ul pozitiv.

- Corelația dintre „Use of Emotional Support” și „Behavioral Disengagement”
Coeficientul este -0.032, indicând o corelație foarte slabă, aproape inexistentă. Semnificația ($p = 0.519$) arată că relația nu este semnificativă statistic.
- Corelația dintre „Behavioral Disengagement” și „Positive Reframing”
Coeficientul de corelație este -0.083, sugerând o relație negativă foarte slabă între aceste variabile. Cu toate acestea, valoarea p (0.099) indică faptul că această corelație nu este semnificativă din punct de vedere statistic.

Heatmap

JASP oferă o reprezentare vizuală a coeficienților sub forma unui heatmap. Culorile intense evidențiază corelațiile mai puternice, iar corelația semnificativă dintre „Use of Emotional Support” și „Positive Reframing” este clar marcată, ceea ce facilitează interpretarea vizuală a relațiilor semnificative.

Interpretarea statistică generală

Analiza outputului sugerează câteva concluzii importante:

- Corelația negativă semnificativă dintre „Use of Emotional Support” și „Positive Reframing” indică o relație complexă între aceste strategii de coping, care merită investigată mai profund.
- Lipsa corelațiilor semnificative între „Behavioral Disengagement” și celelalte variabile sugerează că această strategie nu este direct asociată cu „Use of Emotional Support” sau „Positive Reframing.”

Aceste concluzii evidențiază importanța analizei corelaționale în descoperirea relațiilor dintre variabilele psihosociale și necesitatea explorării contextului în care aceste relații se manifestă.

Analiza de regresie liniară în JASP

Pentru a efectua o analiză de regresie liniară în JASP și a interpreta rezultatele, urmați pașii descriși mai jos, care se bazează pe structura ferestrei de regresie și outputul prezentat în **Figura 6**.

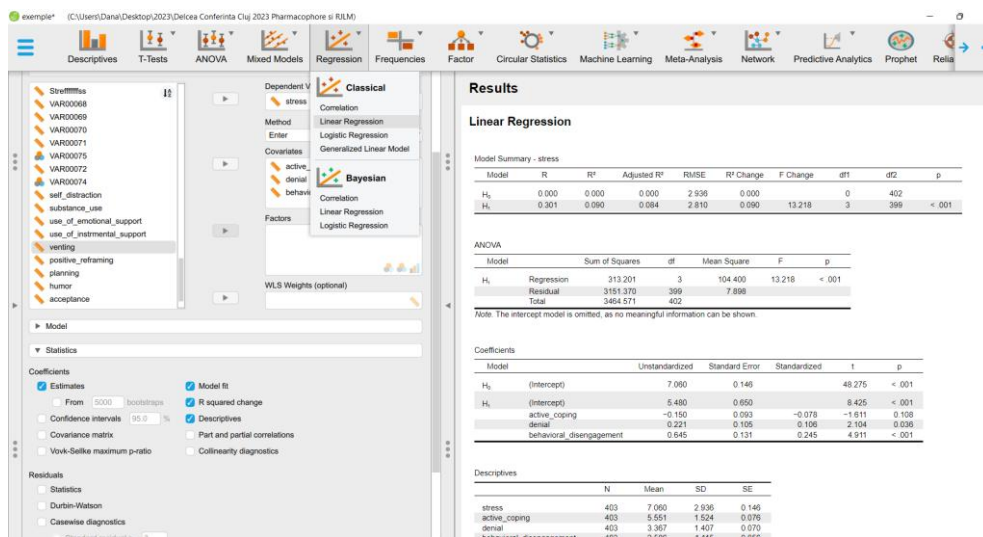


Figura 6. Structura ferestrei de regresie și Output în JASP

Pași detaliați pentru analiza de regresie liniară în JASP:

- Deschiderea setului de date:** Lansați JASP și folosiți opțiunea File > Open pentru a încărca setul de date dorit. Asigurați-vă că setul de date conține variabilele relevante pentru analiza de regresie.
- Selectarea analizei de regresie:** Din meniul principal, navigați la Regression > Linear Regression. Această acțiune va deschide o fereastră de configurare pentru analiza de regresie liniară, unde puteți seta variabilele și opțiunile de raportare.
- Definirea variabilelor:**
 - În secțiunea „Dependent Variable”, selectați variabila dependentă, care în acest exemplu este variabila stress.
 - În secțiunea „Covariates”, selectați variabilele independente (predictorii) pe care doriți să le includeți în model. În acest caz, au fost selectate variabilele „Active Coping,” „Denial,” și „Behavioral Disengagement.”.
- Selectarea opțiunilor de raportare:**
 - Sub „Statistics”, bifați Estimates pentru a include coeficienții de regresie și Confidence intervals pentru a obține intervalele de încredere ale coeficienților.
 - Bifați și opțiunea Model fit pentru a include informații despre potrivirea modelului (de exemplu, R² și ajustările R²).

- Sub „Residuals”, aveți posibilitatea de a selecta opțiuni precum Durbin-Watson pentru a verifica autocorelarea rezidualelor și Collinearity diagnostics pentru a evalua multicolinearitatea variabilelor independente.
5. **Executarea analizei:** După ce ați configurat toate opțiunile, JASP va executa analiza automat și va afișa rezultatele în fereastra de output.

Interpretarea rezultatelor

Rezultatele analizei de regresie sunt afișate în mai multe secțiuni în outputul JASP:

1. Model Summary

- **R² și Adjusted R²:** În acest exemplu, valoarea R² este 0,090, indicând că aproximativ 9% din variabilitatea „Stress” poate fi explicată de variabilele independente „Active Coping,” „Denial,” și „Behavioral Disengagement”.
- **RMSE:** Eroarea standard a estimării este 2,810, oferind o indicație a preciziei modelului.
- **F-test:** Testul F are o valoare semnificativă ($p < ,001$), sugerând că modelul de regresie explică o proporție semnificativă a varianței din variabila dependentă.

2. ANOVA Table

- **Sum of Squares:** Tabelul ANOVA afișează suma pătratelor pentru regresie și reziduale. Valoarea semnificativă a testului F confirmă faptul că modelul este semnificativ.

3. Coefficients Table

- Tabelul „Coefficients” include coeficienții de regresie pentru fiecare variabilă independentă, alături de valorile de semnificație statistică (p-value).
- **Intercept (Constanta):** Coeficientul constant (7,060) este semnificativ ($p < .001$), reprezentând valoarea estimată a „Stress” atunci când valorile predictorilor sunt zero.
- **Active Coping:** Coeficientul pentru „Active Coping” este -0.150, dar nu este semnificativ ($p = .108$), ceea ce indică faptul că această variabilă nu exercită o influență semnificativă asupra „Stress” în acest model.

- **Denial:** Coeficientul pentru denial este 0,457, semnificativ ($p = .036$), ceea ce sugerează că utilizarea negării ca strategie de coping are o influență pozitivă și semnificativă asupra nivelului de stres.
- **Behavioral Disengagement:** Coeficientul pentru „Behavioral Disengagement” este 0.645, semnificativ ($p < .001$), ceea ce indică o relație pozitivă semnificativă între această variabilă și „Stress”.

4. Descriptives

- Secțiunea „Descriptives” oferă informații descriptive despre variabilele incluse, cum ar fi numărul de observații (N), media (Mean), deviația standard (SD), și eroarea standard (SE).

Analiza corelațională în JAMOVI

Pentru a efectua o analiză corelațională în Jamovi, urmați pașii de mai jos, utilizând exemplul din Figura 7 pentru a interpreta rezultatele.

1. Importul datelor

Deschideți Jamovi și încărcați setul de date dorit. Acest lucru se realizează prin opțiunea **File > Open**, unde selectați fișierul în formatul corespunzător (de exemplu, .csv, .sav sau alt format suportat). Datele vor apărea în secțiunea principală, organizate pe variabile și observații.

2. Accesarea analizei corelaționale

Navigați la **Analyses > Regression > Correlation Matrix**. Această opțiune deschide fereastra de configurare a analizei corelaționale, unde veți putea selecta variabilele dorite și alte opțiuni suplimentare.

3. Alegerea variabilelor

În secțiunea **Variables**, selectați variabilele de interes. În exemplul din Figura 7, au fost selectate următoarele variabile:

- „Use of Emotional Support”
- „Positive Reframing”
- „Behavioral Disengagement”

Pentru a adăuga variabile în analiza corelațională, faceți clic pe ele din lista din stânga și apăsați săgeata pentru a le muta în câmpul din dreapta.

4. Alegerea tipului de corelație

În partea de jos a ecranului de configurare, Jamovi oferă opțiuni pentru tipul de corelație:

- **Pearson:** Potrivită pentru relații liniare între variabile numerice.

- **Spearman:** Utilizată pentru relații monotone, adesea în cazul variabilelor ordinale.
- **Kendall's Tau-b:** Utilizată pentru seturi de date mai mici sau când există multe legături.

Selectați tipul de corelație în funcție de scopul analizei. În exemplul din Figura 7, a fost utilizată **Pearson**.

5. Setarea opțiunilor suplimentare

Jamovi permite configurarea următoarelor opțiuni:

- **Flag significant correlations:** Evidențiază corelațiile semnificative statistic (marcate cu asteriscuri în raport).
- **N:** Afișează numărul de observații pentru fiecare pereche de variabile.
- **Confidence intervals:** Oferă intervalele de încredere pentru coeficienții de corelație.

În exemplul prezentat, au fost selectate toate aceste opțiuni, iar intervalul de încredere a fost setat la **95%**.

6. Executarea analizei

După configurarea variabilelor și opțiunilor, rezultatele sunt afișate automat în partea dreaptă a ecranului.

Interpretarea rezultatelor

1. Identificarea coeficienților de corelație

Rezultatele sunt prezentate sub formă de matrice, unde fiecare celulă conține coeficientul de corelație între o pereche de variabile.

- Corelația între „Use of Emotional Support” și „Positive Reframing”: Coeficientul Pearson este 0.311, ceea ce indică o corelație pozitivă moderată. Acest rezultat sugerează că utilizarea „Use of Emotional Support” este asociată cu o tendință crescută de „Positive Reframing.”
- Corelația între „Use of Emotional Support” și „Behavioral Disengagement”: Coeficientul Pearson este -0.032, ceea ce indică o relație foarte slabă și negativă între aceste variabile.

2. Semnificația statistică

Jamovi marchează semnificația statistică utilizând asteriscuri:

- *** pentru $p < 0,001$
- ** pentru $p < 0,01$
- * pentru $p < 0,05$

Relația dintre „Use of Emotional Support” și „Positive Reframing” este semnificativă la nivelul $p < 0.01$, ceea ce indică faptul că probabilitatea ca această relație să fie întâmplătoare este foarte mică. În schimb, relația dintre „Use of Emotional Support” și „Behavioral Disengagement” nu este semnificativă din punct de vedere statistic ($p > 0.05$).

3. Evaluarea direcției și forței relației

Relația dintre „Use of Emotional Support” și „Positive Reframing” este pozitivă, indicând o legătură directă modestă, dar semnificativă între aceste variabile. Acest rezultat sugerează că o utilizare mai frecventă a „Use of Emotional Support” este asociată cu un nivel mai ridicat de „Positive Reframing.” În schimb, relația dintre „Use of Emotional Support” și „Behavioral Disengagement” este foarte slabă și negativă, iar lipsa semnificației statistice indică faptul că nu există o asociere reală între aceste variabile.

Analiza corelațională în Jamovi este simplu de realizat și furnizează informații detaliate despre relațiile dintre variabile. Interpretarea corectă a coeficienților și a semnificației statistice este crucială pentru a înțelege atât direcția, cât și forța acestor relații. În exemplul din Figura 7, „Use of Emotional Support” prezintă o asociere pozitivă și semnificativă cu „Positive Reframing,” în timp ce relația cu „Behavioral Disengagement” este nesemnificativă. Aceste observații subliniază importanța interpretării contextuale a rezultatelor corelaționale.

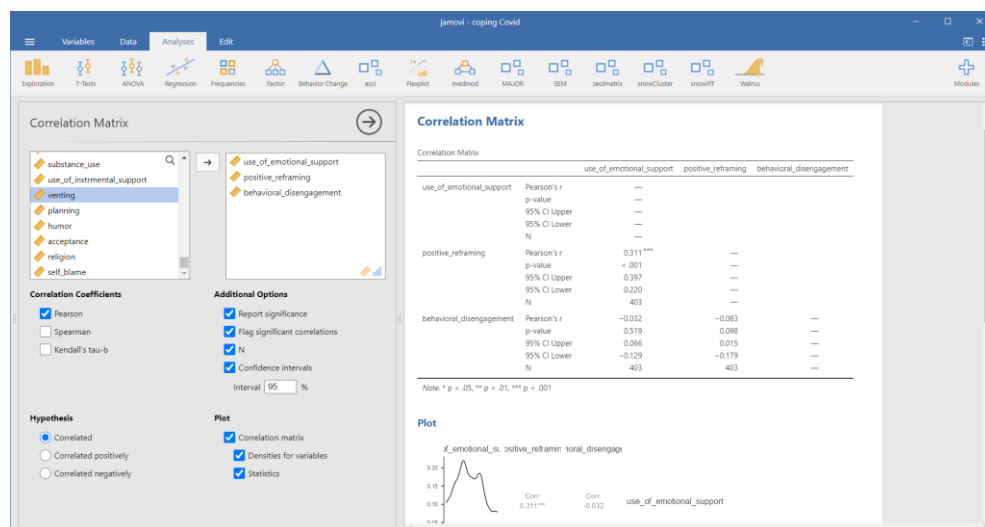


Figura 7. Setarea analizei corelaționale și Output în JAMOVI

Analiza de regresie liniară în JAMOVI

Pentru a efectua o analiză de regresie liniară în Jamovi și a interpreta rezultatele, urmați pașii descriși mai jos, utilizând exemplul din Figura 8 pentru a înțelege structura ferestrei de regresie și a outputului.

1. Deschiderea setului de date

Deschideți Jamovi și utilizați opțiunea **File > Open** pentru a încărca setul de date dorit. Verificați dacă variabilele necesare analizei sunt incluse și corect definite (variabilă dependentă și variabile independente).

2. Selectarea regresiei liniare

Navigați la **Regression > Linear Regression**. Aceasta deschide fereastra de configurare pentru analiza de regresie liniară.

3. Definirea variabilelor

- În câmpul **Dependent Variable**, selectați variabila dependentă. În exemplul nostru, aceasta este stress.
- În câmpul **Covariates**, adăugați predictorii. În exemplul dat, predictorii sunt „Positive Reframing,” „Acceptance,” „Active Coping,” „Use of Instrumental Support” și „Behavioral Disengagement.”

4. Alegerea opțiunilor suplimentare

Pentru o analiză detaliată:

- Sub **Model Fit Measures**, bifați **R²** și **Adjusted R²** pentru a evalua proporția de variabilitate explicată de model.
- Bifați **Confidence intervals** pentru a include intervalele de încredere ale coeficienților de regresie.
- Dacă este necesar, activați opțiunile suplimentare pentru analiza reziduurilor și diagnosticarea multicolinearității.

5. Executarea analizei

După selectarea variabilelor și configurarea opțiunilor, Jamovi va calcula automat modelul și va afișa rezultatele.

Interpretarea rezultatelor

1. Model Fit Measures

- **R**: Coeficientul de corelație multiplă este **0.304**, indicând o relație modestă între variabilele independente și variabila dependentă.

- **R²**: Valoarea **R²** este **0.0926**, ceea ce indică faptul că predictorii explica aproximativ 9,3% din variabilitatea variabilei stress.
- **Adjusted R²**: Valoarea ajustată este **0.0811**, ceea ce sugerează că modelul este robust și că proporția explicată a varianței este corectată în funcție de numărul de predictorii.
- **F-Test**: Valoarea F este **8.08** cu **df1 = 5** și **df2 = 396**, iar semnificația statistică este **p < .001**, indicând că modelul explică o proporție semnificativă a varianței variabilei dependente.

2. Omnibus ANOVA Test

Tabelul ANOVA arată semnificația fiecărei variabile independente:

- **„Positive Reframing”**: F = 0.00706, p = 0.933. Nu are o influență semnificativă asupra „Stress”.
- **„Acceptance”**: F = 10.81747, p = 0.001. Are o influență pozitivă și semnificativă asupra „Stress”.
- **„Active Coping”**: F = 0.21478, p = 0.643. Nu are o influență semnificativă asupra „Stress.”
- **„Use of Instrumental Support”**: F = 0.52992, p = 0.467. Nu are o influență semnificativă asupra „Stress”.
- **„Behavioral Disengagement”**: F = 17.76955, p < .001. Are o influență negativă și semnificativă asupra „Stress”.

3. Model Coefficients

Tabelul coeficienților oferă detalii despre impactul predictorilor asupra variabilei dependente:

- **Intercept**: Coeficientul constant este **16.49630**, semnificativ (**p < .001**), reprezentând valoarea estimată a stress atunci când valorile predictorilor sunt zero.
- **„Positive Reframing”**: Coeficientul este -0.00719, nesemnificativ (p = 0.933), ceea ce sugerează că această variabilă nu influențează „Stress”.
- **„Acceptance”**: Coeficientul este 0.32139, semnificativ (p = 0.001), indicând că această variabilă are o influență pozitivă semnificativă asupra „Stress”.
- **„Active Coping”**: Coeficientul este 0.03710, nesemnificativ (p = 0.643), ceea ce indică o influență nesemnificativă asupra „Stress”.

- **„Use of Instrumental Support”**: Coeficientul este 0.05486, nesemnificativ ($p = 0.467$), indicând faptul că această variabilă nu are o influență semnificativă asupra „Stress.”
- **„Behavioral Disengagement”**: Coeficientul este -0.41429, semnificativ ($p < .001$), ceea ce indică o relație negativă semnificativă cu „Stress”.

4. Intervalele de încredere

Intervalele de încredere de 95% pentru coeficienți oferă informații despre variabilitatea estimărilor:

- De exemplu, pentru „Behavioral Disengagement,” intervalul de încredere este între -0.6075 și -0.221, confirmând semnificația relației negative dintre această variabilă și „Stress.”
- Modelul de regresie liniară indică faptul că „Stress” este influențat semnificativ de „Acceptance” (în mod pozitiv) și „Behavioral Disengagement” (în mod negativ). Celelalte variabile independente nu au avut un impact semnificativ asupra „Stress.”
- Valoarea ajustată a lui R^2 sugerează că predictorii explică o proporție modestă din variabilitatea „Stress,” ceea ce subliniază necesitatea de a explora alți factori care pot contribui la acest fenomen.

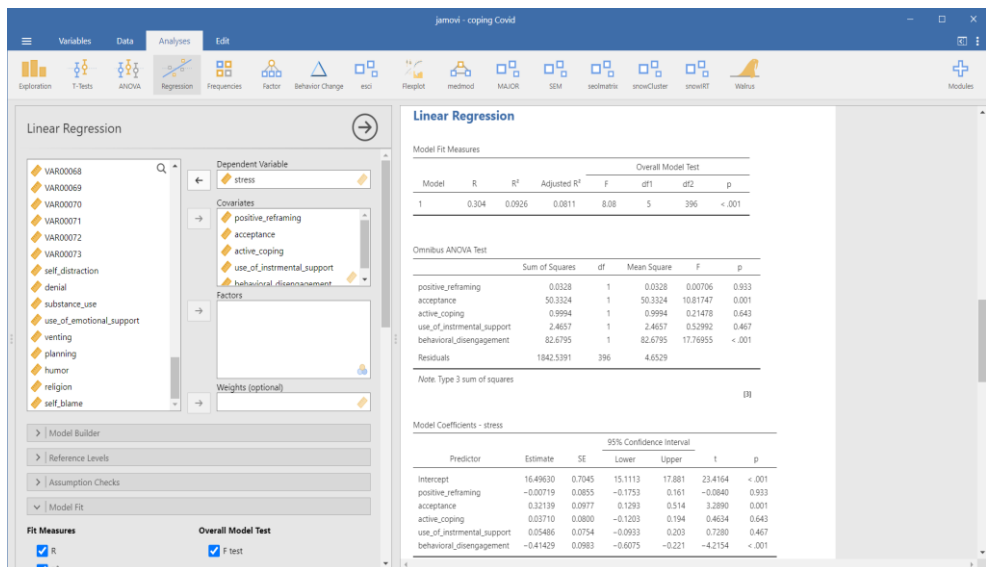


Figura 8. Structura ferestrei de regresie și Output în JAMOVI

7.3. Ghid practic pentru utilizarea software-urilor în analize de mediere și moderare

Analiza de mediere și/sau moderare este esențială pentru a înțelege mecanismele și condițiile prin care variabilele influențează între ele. **Medierea** explorează **cum și prin ce mecanisme** o variabilă independentă (X) influențează o variabilă dependentă (Y), identificând rolul unei variabile intermediare, numită mediator (M). **Moderarea**, pe de altă parte, analizează **în ce condiții sau pentru cine** relația dintre X și Y este mai puternică sau mai slabă, implicând rolul unei variabile de moderare (W).

Tipurile de analize și modelele din PROCESS Macro sunt utilizate în funcție de ipotezele formulate:

- **Modelul 1 (Moderare simplă):** Testează dacă efectul unei variabile independente asupra variabilei dependente este influențat de un moderator.
- **Modelul 4 (Mediere simplă):** Examinează dacă relația dintre X și Y este explicată printr-un singur mediator.
- **Modelul 4 (Mediere paralelă):** Analizează mai mulți mediatori care acționează independent (în paralel) asupra relației $X \rightarrow Y$.
- **Modelul 6 (Mediere secvențială):** Testează dacă relația $X \rightarrow Y$ este mediată printr-o succesiune de mediatori, în ordinea specificată.
- **Modelele 7 și 8 (Mediere moderată):** Integrează atât medierea, cât și moderarea, explorând modalitatea în care variabilele moderatoare influențează relațiile mediate.

Pentru a efectua analize de mediere și moderare, SPSS și macro-ul PROCESS sunt esențiale. JASP și JAMOVI includ, de asemenea, module pentru astfel de analize.

Mai jos sunt pașii detaliați pentru efectuarea analizelor de mediere și moderare folosind PROCESS Macro, pentru modelele corespunzătoare:

1. Moderare – Modelul 1 (Moderare simplă)

1. Importați datele în SPSS.
2. Accesați **Analyze > Regression > PROCESS v4.0 by Andrew F. Hayes.**

3. Selectați **Model 1** pentru analiza de moderare simplă.
4. Specificați variabilele:
 - **X**: Variabila independentă.
 - **M**: Moderatorul.
 - **Y**: Variabila dependentă.
5. Selectați opțiuni suplimentare, cum ar fi bootstrap (ex. 5000 de eșantioane) și intervalele de încredere.
6. Rulați analiza făcând clic pe **OK**.

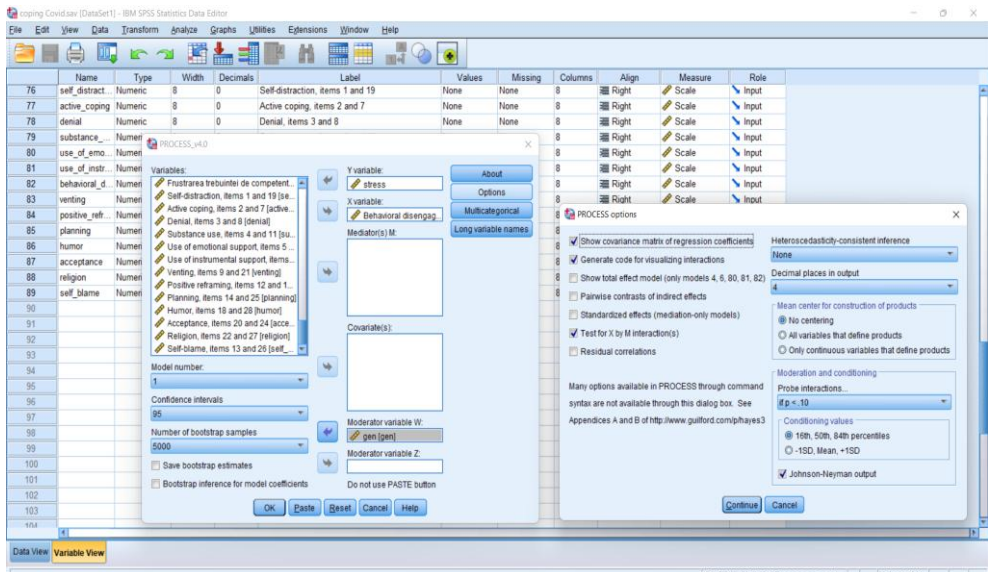


Figura 9. Interfața pentru analiza moderării simple

În acest exemplu, ipoteza principală postulează că relația dintre „Behavioral Disengagement” (variabila independentă, X) și „Stress” (variabila dependentă, Y) este moderată de nivelul „Status Marital” (variabila moderatoare, M). Mai specific, analiza urmărește să determine dacă efectul „Behavioral Disengagement” asupra „Stress” diferă în funcție de statutul marital al individului, cum ar fi persoanele singure comparativ cu cele căsătorite sau căsătorite cu copii. Această ipoteză reflectă faptul că statutul marital poate funcționa ca un factor contextual care amplifică sau atenuează impactul comportamentului de dezangajare asupra stresului.

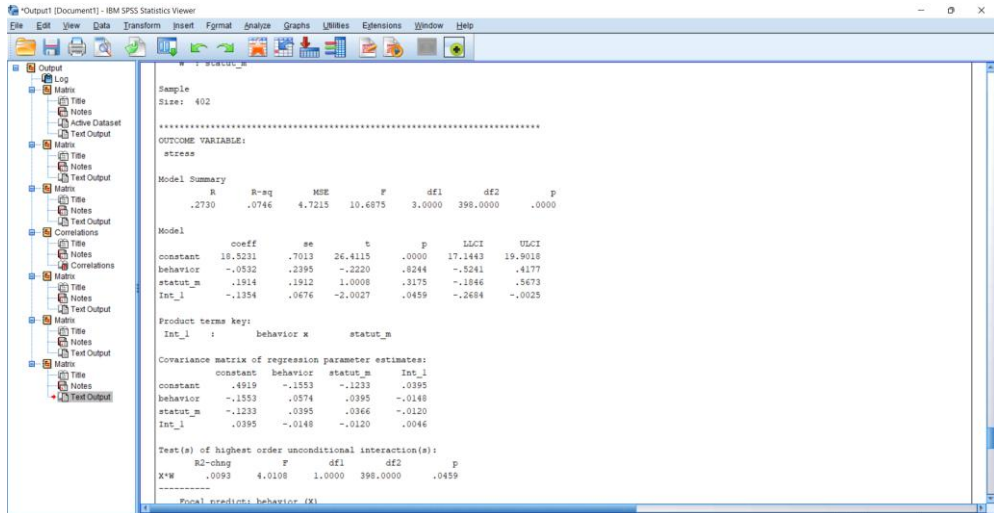


Figura 10. SPSS Output pentru analiza moderării simple

Modelul analizează relația dintre „Behavioral Disengagement” (variabila independentă, X) și „Stress” (variabila dependentă, Y), moderată de „Statut Marital” (variabila moderatoare, W), așa cum este ilustrat în Figura 10. Moderarea explorează dacă efectul variabilei X asupra variabilei Y variază în funcție de nivelul „Statutului Marital.” În acest context, scorurile mai mici pentru moderator indică starea de a fi singur, în timp ce scorurile mai mari reflectă statutul de a fi căsătorit cu copii. Analiza urmărește să identifice dacă și cum condițiile contextuale legate de statutul marital influențează relația dintre comportamentul de dezangajare și nivelul de stres.

1. Rezumatul modelului (Model Summary)

- $R = 0.2730$ și $R^2 = 0.0746$: Aproximativ 7.46% din variabilitatea în stress este explicată de model (inclusiv interacțiunea).
- $F(3, 398) = 10.6875$, $p < 0.001$: Modelul global este semnificativ statistic, ceea ce sugerează că relația dintre variabilele incluse este relevantă.

2. Coeficienții de regresie

Variabilă	Coeficient (b)	SE	t	p	LLCI	ULCI
Constant	18.5231	0.7013	26.4115	<0.001	17.1443	19.9018
Behavior	-0.0532	0.2395	-0.2220	0.8244	-0.5241	0.4177

Variabilă	Coeficient (b)	SE	t	p	LLCI	ULCI
Statut_m	0.1914	0.1912	1.0008	0.3175	-0.1846	0.5673
Int_1 (Interacțiunea)	-0.1354	0.0676	-2.0027	0.0459	-0.2684	-0.0025

- **Intercept:** Reprezintă valoarea medie a „Stress” atunci când „Behavioral Disengagement” și „Statut Marital” sunt la nivelul 0.
- **Behavior:** Nu are un efect direct semnificativ asupra „Stress” ($p = 0.8244$), ceea ce sugerează că această variabilă nu influențează direct nivelul de stres.
- **Statut_m:** „Statutul Marital” nu influențează semnificativ nivelul de „Stress” în mod direct ($p = 0.3175$).
- **Interacțiunea (Int_1):** Relația dintre „Behavioral Disengagement” și „Stress” este semnificativ moderată de „Statut Marital” ($p = 0.0459$), indicând faptul că efectul „Behavioral Disengagement” asupra „Stress” variază în funcție de statutul marital.

3. Testul interacțiunii (Test of Unconditional Interaction)

- $\Delta R^2 = 0.0093$, $F(1, 398) = 4.0108$, $p = 0.0459$: Interacțiunea explică o proporție suplimentară semnificativă a varianței în stres.

4. Efecte condiționale la valori diferite ale moderatorului (statut_m)

Statut_m (percentile)	Effect	SE	t	p	LLCI	ULCI
1.4800 (Singur)	-0.2536	0.1537	-1.6502	0.0997	-0.5558	0.0485
4.0000 (Căsătorit)	-0.5949	0.1107	-5.3722	<0.001	-0.8127	-0.3772
5.0000 (Căsătorit cu copii)	-0.7304	0.1545	-4.7287	<0.001	-1.0340	-0.4267

- Când „Statut Marital” este mic (aproximativ 1.48 - persoane singure), efectul „Behavioral Disengagement” asupra „Stress” nu este semnificativ, sugerând că această variabilă nu influențează nivelul de stres în acest context.
- Când „Statut Marital” crește (4.0 - persoane căsătorite), efectul „Behavioral Disengagement” devine semnificativ negativ, indicând că o creștere a „Behavioral Disengagement” este asociată cu o reducere a „Stress.”

- **Pentru scoruri mai mari ale „Statut Marital” (5.0 - căsătorit cu copii),** relația negativă dintre „Behavioral Disengagement” și „Stress” devine și mai puternică, sugerând o influență mai pronunțată în acest context marital specific.

5. Regiuni de semnificație (Johnson-Neyman)

- **Regiunea Johnson-Neyman** indică o valoare critică a „Statutului Marital” de 1.6862, sub care efectul focal, respectiv relația dintre „Behavioral Disengagement” și „Stress,” devine nesemnificativ. Acest lucru sugerează că, pentru indivizii cu un „Statut Marital” sub acest prag (de exemplu, persoane singure), „Behavioral Disengagement” nu are un impact semnificativ asupra „Stress.”
- **Pentru valori ale „Statutului Marital” peste acest prag,** efectul „Behavioral Disengagement” asupra „Stress” devine semnificativ, indicând că relația dintre aceste variabile este condiționată de statutul marital, având un impact mai pronunțat în contextul persoanelor căsătorite sau căsătorite cu copii.

Astfel:

- Relația dintre „Behavioral Disengagement” și „Stress” devine semnificativă doar atunci când „Statutul Marital” atinge un anumit nivel, caracteristic persoanelor căsătorite sau căsătorite cu copii.
- Pentru persoanele singure, „Behavioral Disengagement” nu are un efect semnificativ asupra nivelului de stres, ceea ce indică faptul că în acest context, această strategie de coping nu influențează percepția stresului.
- Efectul negativ al „Behavioral Disengagement” asupra „Stress” crește în magnitudine odată cu creșterea nivelului „Statutului Marital.” Acest rezultat sugerează că persoanele căsătorite sau cele cu copii resimt mai mult impactul comportamentului de dezangajare asupra reducerii stresului, posibil datorită unui sprijin emoțional mai puternic sau al unui sistem mai robust de suport social.

Această moderare evidențiază faptul că responsabilitățile familiale sau sprijinul marital pot modifica modul în care strategiile de coping, precum „Behavioral Disengagement,” influențează stresul. Aceste descoperiri

subliniază importanța contextului social și familial în procesul de reglare emoțională și gestionare a stresului.

2. Mediere simplă - Modelul 4 cu un mediator

1. Importați datele în SPSS.
2. Navigați la **Analyze > Regression > PROCESS v4.0 by Andrew F. Hayes**.
3. Selectați **Model 4** pentru o mediere simplă.
4. Definiți variabilele:
 - **X:** Variabila independentă.
 - **M:** Mediatorul.
 - **Y:** Variabila dependentă.
5. Configurați bootstrap pentru estimări robuste.
6. Rulați analiza făcând clic pe **OK**.

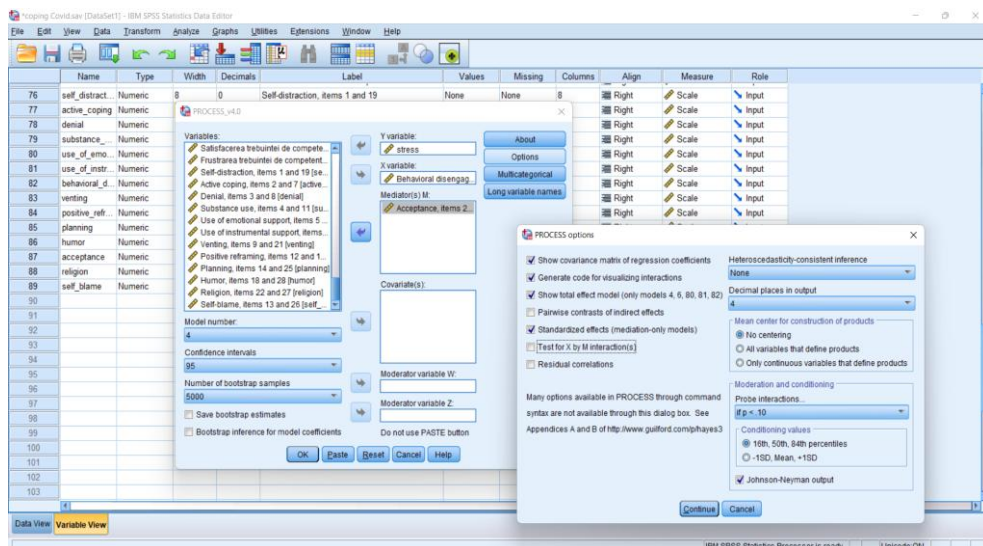


Figura 11. Interfața pentru analiza de mediere simplă

În exemplul de mai sus, utilizarea **Modelului 4** urmărește să testeze dacă „Acceptance” (acceptarea situației) funcționează ca un mecanism psihologic prin care „Behavioral Disengagement” influențează „Stress.” Analiza se concentrează pe identificarea efectelor directe și indirecte, oferind o perspectivă mai clară asupra modului în care strategiile de coping influențează percepția stresului.

1. Modelul pentru mediator (acceptance)

Acest model analizează relația dintre variabila independentă, „Behavioral Disengagement” (behavior), și mediatorul, „Acceptance.”

Rezumatul modelului:

- **R = 0.1570, R² = 0.0247, p = 0.0016:** Rezultatele indică faptul că aproximativ 2.47% din variabilitatea lui „Acceptance” este explicată de „Behavioral Disengagement.” Modelul este semnificativ statistic, ceea ce sugerează că există o relație directă semnificativă între „Behavioral Disengagement” și „Acceptance.”

Acest rezultat subliniază faptul că „Behavioral Disengagement” joacă un rol modest, dar semnificativ, în influențarea „Acceptance” ca mecanism psihologic. Această legătură este esențială pentru a înțelege cum strategiile de coping pasiv contribuie la procesele psihologice implicate în gestionarea stresului.

Coefficienți:

Variabilă	Coefficient (b)	SE	t	p	LLCI	ULCI
Constant	6.8168	0.1570	43.4138	<0.001	6.5081	7.1255
Behavior	-0.1773	0.0557	-3.1802	0.0016	-0.2868	-0.0677

- Relația dintre „Behavioral Disengagement” și „Acceptance” este semnificativă (**p = 0.0016**) și negativă, ceea ce sugerează că un nivel mai ridicat de „Behavioral Disengagement” este asociat cu un nivel mai scăzut de „Acceptance.”

Această constatare indică faptul că utilizarea mai frecventă a strategiilor de coping pasiv, precum dezangajarea comportamentală, reduce capacitatea individului de a accepta situația, ceea ce poate avea implicații importante în înțelegerea proceselor de reglare emoțională și adaptare psihologică.

2. Modelul pentru variabila dependentă (stress)

Acest model explorează relația dintre „Behavioral Disengagement,” „Acceptance” și „Stress,” oferind o perspectivă asupra influenței combinate a acestor variabile.

Rezumatul modelului:

- **R = 0.3004, R² = 0.0902, p < 0.001:** Rezultatele indică faptul că aproximativ 9.02% din variabilitatea lui „Stress” este explicată de „Behavioral Disengagement” și „Acceptance.” Modelul este semnificativ din punct de vedere statistic, ceea ce sugerează că aceste variabile joacă un rol important în determinarea nivelului de stres.

Aceste descoperiri subliniază importanța atât a mecanismelor directe, cât și a celor indirecte, prin care „Behavioral Disengagement” și „Acceptance” influențează „Stress,” evidențiind complexitatea proceselor psihologice implicate în reglarea stresului.

Coefficienți:

Variabilă	Coefficient (b)	SE	t	p	LLCI	ULCI
Constant	16.7197	0.6482	25.7939	<0.001	15.4454	17.9940
Behavior	-0.4052	0.0975	-4.1567	<0.001	-0.5969	-0.2136
Acceptance	0.3463	0.0864	4.0097	0.0001	0.1765	0.5161

- **Relația dintre „Behavioral Disengagement” și „Stress”** este semnificativă (**p < 0.001**) și negativă, ceea ce indică faptul că un nivel mai mare de „Behavioral Disengagement” este asociat cu un nivel mai scăzut de „Stress.”
- **Mediatorul „Acceptance”** are, de asemenea, o relație semnificativă pozitivă cu „Stress” (**p = 0.0001**), ceea ce sugerează că un nivel mai mare de „Acceptance” este asociat cu un nivel mai ridicat de „Stress.”
- Aceste rezultate subliniază natura duală a influenței variabilelor, în care „Behavioral Disengagement” reduce stresul în mod direct, dar „Acceptance,” acționând ca mediator, contribuie la creșterea nivelului de stres. Această dinamică complexă sugerează că strategiile de coping și procesele psihologice pot avea efecte contradictorii asupra percepției stresului.

3. Modelul efectului total (behavior → stress)

Acest model examinează **efectul direct** al „Behavioral Disengagement” asupra „Stress,” fără a lua în considerare mediatorul.

Rezumatul modelului:

- **R = 0.2314, R² = 0.0536, p < 0.001:** Rezultatele arată că aproximativ 5.36% din variabilitatea lui „Stress” este explicată de „Behavioral Disengagement.” Modelul este semnificativ statistic, ceea ce indică o relație semnificativă între aceste variabile.
- Aceste rezultate sugerează că „Behavioral Disengagement” are un efect direct modest, dar semnificativ, asupra nivelului de stres, demonstrând că strategiile de coping pasiv influențează percepția stresului independent de alte mecanisme psihologice.

Coficienți:

Variabilă	Coficient (b)	SE	t	p	LLCI	ULCI
Constant	19.0803	0.2763	69.0604	<0.001	18.5372	19.6235
Behavior	-0.4666	0.0981	-4.7577	<0.001	-0.6594	-0.2738

- **Efectul total al „Behavioral Disengagement” asupra „Stress”** este semnificativ (**p < 0.001**) și negativ, ceea ce indică faptul că o creștere a utilizării „Behavioral Disengagement” este asociată cu o reducere semnificativă a nivelului de „Stress.”
- Această constatare sugerează că strategiile de dezangajare comportamentală au un impact direct și global asupra stresului, fără a depinde de intervenția altor variabile, consolidând rolul lor ca mecanism de coping relevant în gestionarea stresului.

4. Efectele directe și indirecte

Tip efect	Coficient (b)	SE	LLCI	ULCI	p
Total	-0.4666	0.0981	-0.6594	-0.2738	<0.001
Direct	-0.4052	0.0975	-0.5969	-0.2136	<0.001
Indirect	-0.0614	0.0306	-0.1323	-0.0140	N/A

- **Efectul indirect:** Relația dintre „Behavioral Disengagement” și „Stress” prin „Acceptance” este semnificativă, conform intervalului de încredere bootstrap (BootLLCI = -0.1323, BootULCI = -0.0140). Acest rezultat indică faptul că „Acceptance” mediază parțial această relație, sugerând că o parte din influența „Behavioral Disengagement” asupra „Stress” este transmisă prin mecanismul de acceptare a situației.

- **Efectul direct:** Chiar și după ce mediatorul „Acceptance” este inclus în model, „Behavioral Disengagement” are un efect semnificativ asupra „Stress,” ceea ce sugerează că există și alte mecanisme psihologice sau contextuale, în afară de „Acceptance,” care contribuie la această relație.
- Aceste rezultate reflectă o dinamică complexă între variabile, în care „Acceptance” explică doar o parte din influența comportamentului de dezangajare asupra stresului. Identificarea altor posibili mediatori ar putea oferi o înțelegere mai completă a proceselor prin care strategiile de coping pasiv afectează percepția stresului.

Astfel,

- Relația totală dintre „Behavioral Disengagement” și „Stress” este semnificativă și negativă, ceea ce indică faptul că utilizarea „Behavioral Disengagement” contribuie global la reducerea „Stress.”
- „Acceptance” acționează ca un mediator parțial, explicând o parte semnificativă a relației dintre „Behavioral Disengagement” și „Stress.”
- Efectul indirect (-0.0614) sugerează că „Behavioral Disengagement” reduce nivelul de „Acceptance,” care, la rândul său, crește nivelul de „Stress.” Acest mecanism indică faptul că, deși „Behavioral Disengagement” poate avea un impact direct asupra stresului, influențează și prin intermediul „Acceptance,” creând un efect dual asupra percepției stresului.
- Cu toate acestea, efectul direct al „Behavioral Disengagement” asupra „Stress” rămâne semnificativ, ceea ce evidențiază existența altor mecanisme psihologice sau contextuale care contribuie la această relație.

Această mediere parțială subliniază rolul important al „Acceptance” ca mecanism psihologic în înțelegerea stresului, dar indică, de asemenea, necesitatea investigării altor variabile care pot influența relația dintre „Behavioral Disengagement” și „Stress.” Identificarea acestor variabile ar putea aduce claritate suplimentară asupra strategiilor de coping pasiv și a efectelor acestora asupra sănătății mentale.

3. Mediere paralelă - Modelul 4 cu mai mulți mediatori

1. Importați datele în SPSS.
2. Accesați **Analyze > Regression > PROCESS v4.0 by Andrew F. Hayes.**
3. Selectați **Model 4** pentru analiza de mediere paralelă.
4. Specificați variabilele:
 - o **X:** Variabila independentă.
 - o **M1, M2, M3** (etc.): Mediatorii paraleli.
 - o **Y:** Variabila dependentă.
5. Asigurați-vă că bifați opțiunea de estimare bootstrap pentru rezultate exacte.
6. Rulați analiza.

Aceasta analizează efectele variabilei X asupra Y prin mai mulți mediatori în paralel.

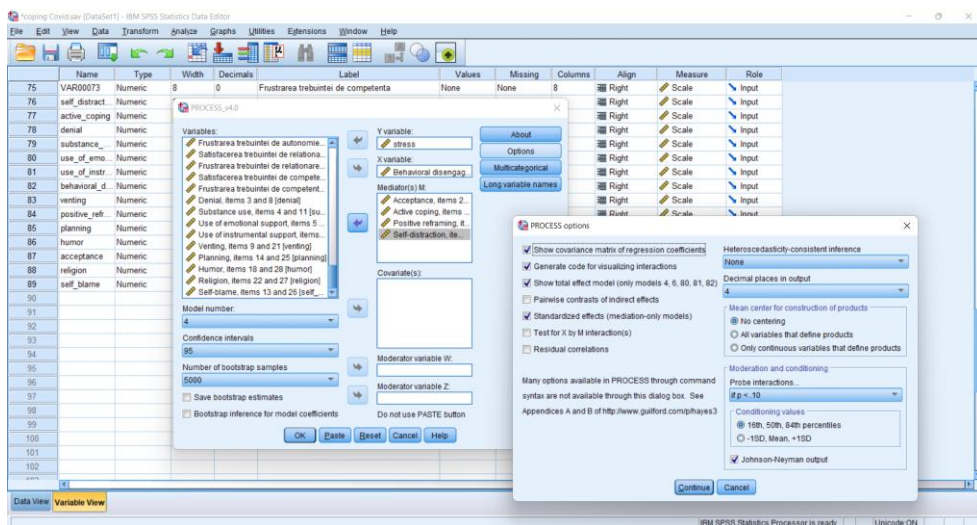


Figura 13. Interfața pentru analiza de mediere paralelă

Prin utilizarea **Modelului 4** cu patru mediatori, analiza își propune să testeze cum și prin ce mecanisme specifice „Behavioral Disengagement” (X) influențează „Stress” (Y). Acest model paralel de mediere examinează rolul simultan al celor patru mediatori, oferind o perspectivă detaliată asupra proceselor psihologice implicate.

Ipoteza testată: Relația dintre „Behavioral Disengagement” și „Stress” este transmisă prin intermediul a patru mediatori paraleli, fiecare reprezentând o strategie specifică de coping:

1. **Acceptance (M1):** Reflectă gradul în care individul acceptă situația stresantă ca fiind inevitabilă, posibil reducând conflictul emoțional asociat.
2. **Self-Distractiion (M2):** O strategie de coping care implică deturnarea atenției de la sursa de stres prin activități care distrag mintea.
3. **Denial (M3):** O strategie de coping prin care individul refuză să recunoască realitatea situației stresante, ceea ce poate întârzia adaptarea psihologică.
4. **Active Coping (M4):** Măsura în care individul răspunde activ și constructiv la stres, încercând să rezolve problema sau să diminueze efectele acesteia.

Rezultatele așteptate:

- Analiza va evidenția dacă fiecare mediator are o contribuție semnificativă la transmiterea efectului „Behavioral Disengagement” asupra „Stress.”
- Se va determina proporția efectului total al lui „Behavioral Disengagement” care este transmisă prin fiecare mediator.
- Se va explora dacă vreun mediator are o influență predominantă, ceea ce ar putea sugera un mecanism principal de transmisie.

Relevanța cercetării

Identificarea strategiilor de coping care mediază această relație este esențială pentru înțelegerea dinamicii psihologice a stresului și pentru dezvoltarea unor intervenții personalizate. De exemplu, dacă „Acceptance” se dovedește a fi un mediator important, intervențiile ar putea fi orientate spre promovarea acceptării ca strategie de adaptare. În schimb, dacă „Denial” sau „Self-Distractiion” sunt identificate ca fiind semnificative, aceste rezultate ar putea sugera necesitatea unor intervenții care să abordeze strategiile de coping mai puțin adaptative.

„Behavioral Disengagement” influențează percepția stresului, reprezentând un posibil punct de intervenție în strategiile de management al stresului.

Mediator 2: Active Coping

- $R^2 = 0.0003$, $p = 0.7121$: Relația dintre „Behavioral Disengagement” și „Active Coping” nu este semnificativă, sugerând că dezangajarea comportamentală nu explică variabilitatea în strategia de coping activ.
- Efectul lui „Behavioral Disengagement” asupra „Active Coping”:
 $b = -0.0252$, $p = 0.7121$: Nu există o relație semnificativă, indicând că nivelul de dezangajare comportamentală nu influențează utilizarea strategiilor active de coping.

Mediator 3: Positive Reframing

• $R^2 = 0.0066$, $p = 0.1029$: Relația dintre „Behavioral Disengagement” și „Positive Reframing” nu este semnificativă, ceea ce indică faptul că dezangajarea comportamentală explică foarte puțin din variabilitatea în reframing-ul pozitiv.

- Efectul lui „Behavioral Disengagement” asupra „Positive Reframing”:
 $b = -0.1090$, $p = 0.1029$: Nu există o relație semnificativă, sugerând că utilizarea strategiilor de dezangajare comportamentală nu are un impact clar asupra tendinței de reframing pozitiv.

Mediator 4: Self-Distraction

- $R^2 = 0.0000$, $p = 0.9949$: Relația dintre „Behavioral Disengagement” și „Self-Distraction” nu este semnificativă, ceea ce arată că dezangajarea comportamentală nu explică variabilitatea în strategia de distragere de sine.
- Efectul lui „Behavioral Disengagement” asupra „Self-Distraction”:
 $b = -0.0004$, $p = 0.9949$: Nu există o relație semnificativă, ceea ce sugerează că dezangajarea comportamentală nu are nicio influență asupra utilizării strategiilor de auto-distragere.

Dintre cei patru mediatori analizați (**acceptance, active coping, positive reframing, self-distraction**), doar **acceptance** demonstrează o relație semnificativă cu „Behavioral Disengagement.” Acest rezultat subliniază faptul că **acceptarea** acționează ca un mecanism psihologic relevant prin care dezangajarea comportamentală influențează nivelul de

stres. Relația semnificativă și negativă dintre „Behavioral Disengagement” și „Acceptance” sugerează că persoanele care adoptă strategii de dezangajare comportamentală tind să accepte mai puțin situațiile stresante, ceea ce poate contribui la menținerea sau creșterea stresului.

În contrast, ceilalți trei mediatori (**active coping, positive reframing, self-distraction**) nu prezintă relații semnificative, indicând că aceste strategii de coping nu sunt influențate de nivelul de dezangajare comportamentală. Acest lucru evidențiază faptul că nu toate strategiile de coping sunt relevante în contextul analizat și sugerează că selectarea mediatorilor trebuie să fie ghidată de ipoteze teoretice clare și de o înțelegere aprofundată a mecanismelor psihologice implicate. Rezultatele susțin importanța **acceptării** ca factor central în înțelegerea dinamicii dintre dezangajare și stres, oferind o bază pentru intervenții psihologice care să vizeze această strategie de coping.

2. Model pentru variabila dependentă (stress)

Acest model analizează efectele variabilelor „Behavioral Disengagement,” „Acceptance,” „Active Coping,” „Positive Reframing,” și „Self-Distractiion” asupra variabilei dependente „Stress.” Modelul urmărește să determine măsura în care fiecare dintre aceste variabile explică variabilitatea nivelului de stres, evidențiind atât efectele directe, cât și relațiile dintre strategiile de coping și percepția stresului.

- **$R^2 = 0.0940$, $p < 0.001$:** Aproximativ **9.4%** din variabilitatea lui „Stress” este explicată de model (**$R^2 = 0.0940$**). Acest rezultat indică faptul că predictorii incluși în analiză – „Behavioral Disengagement,” „Acceptance,” „Active Coping,” „Positive Reframing,” și „Self-Distractiion” – contribuie în mod semnificativ la explicarea stresului perceput. Deși procentul de variabilitate explicată este modest, acesta sugerează că strategiile de coping analizate joacă un rol relevant în influențarea nivelului de stres, dar există și alți factori suplimentari care ar putea contribui la variabilitatea stresului și care nu au fost incluși în model. Această observație subliniază complexitatea mecanismelor psihologice implicate în percepția și gestionarea stresului.

• **Efectele directe și indirecte:**

Variabilă	Coeficient (b)	SE	t	p	LLCI	ULCI
behavior	-0.4017	0.0979	-4.1044	<0.001	-0.5941	-0.2093
acceptance	0.3376	0.0983	3.4339	0.0007	0.1443	0.5309
active_coping	0.0814	0.0825	0.9861	0.3247	-0.0809	0.2436
positive_reframing	0.0282	0.0866	0.3256	0.7449	-0.1421	0.1984
self_distraction	-0.0973	0.0908	-1.0721	0.2843	-0.2758	0.0811

Interpretare:

- Behavioral Disengagement: Prezintă un efect direct negativ semnificativ asupra „Stress” ($b = -0.4017$, $p < 0.001$), indicând faptul că o creștere în utilizarea dezangajării comportamentale este asociată cu o reducere a nivelului de stres perceput. Acest rezultat poate reflecta o formă paradoxală de reducere a stresului prin evitarea activă a confruntării cu situațiile stresante.
- Acceptance: Este singurul mediator din model care are un efect semnificativ pozitiv asupra „Stress” ($b = 0.3376$, $p = 0.0007$). Acest rezultat sugerează că un nivel mai ridicat de acceptare a situațiilor dificile este asociat cu o creștere a stresului perceput, ceea ce ar putea indica faptul că acceptarea, deși o strategie adaptativă, poate fi insuficientă pentru a reduce stresul în anumite contexte.
- Active Coping, Positive Reframing, Self-Distraction: Acești mediatori nu prezintă efecte semnificative asupra „Stress,” ceea ce indică faptul că utilizarea acestor strategii de coping nu influențează în mod direct nivelul de stres perceput în acest model specific.

3. Efectele totale, directe și indirecte

Tip efect	Coeficient (b)	SE	LLCI	ULCI	p
Total	-0.4666	0.0981	-0.6594	-0.2738	<0.001
Direct	-0.4017	0.0979	-0.5941	-0.2093	<0.001
Indirect (TOTAL)	-0.0649	0.0308	-0.1350	-0.0163	N/A

Efecte indirecte pe mediatori:

Mediator	Efect (b)	BootSE	BootLLCI	BootULCI
acceptance	-0.0598	0.0301	-0.1302	-0.0132
active_coping	-0.0020	0.0071	-0.0192	0.0106

Mediator	Efect (b)	BootSE	BootLLCI	BootULCI
positive_reframing	-0.0031	0.0094	-0.0246	0.0152
self_distraction	0.0000	0.0082	-0.0191	0.0163

Interpretare

- Mediatorul „Acceptance” contribuie semnificativ la efectul indirect total (-0.0598, CI [-0.1302, -0.0132]), ceea ce indică faptul că acceptarea este un mecanism prin care „Behavioral Disengagement” influențează „Stress.”
- Ceilalți mediatori – „Active Coping,” „Positive Reframing,” și „Self-Distraction” – nu prezintă efecte indirecte semnificative, sugerând că aceste strategii de coping nu mediază relația dintre dezangajarea comportamentală și stres.

Analiza detaliată relevă:

1. Efectul total al lui „Behavioral Disengagement” asupra „Stress” (-0.4666) este semnificativ, subliniind că un nivel mai ridicat de dezangajare comportamentală este asociat cu o reducere a stresului. Acest rezultat poate indica faptul că, în anumite contexte, evitarea activă sau dezangajarea comportamentală poate servi ca o strategie de protecție împotriva stresului.
2. „Acceptance” este singurul mediator semnificativ, explicând o parte din relația dintre „Behavioral Disengagement” și „Stress.” Acest lucru sugerează că, atunci când oamenii își acceptă situațiile stresante, această acceptare poate modula efectul dezangajării asupra stresului. Cu toate acestea, având în vedere că efectul mediat este relativ modest, acceptarea explică doar parțial această relație.
3. Mediatorii „Active Coping,” „Positive Reframing,” și „Self-Distraction” nu au contribuit semnificativ la relația dintre „Behavioral Disengagement” și „Stress,” ceea ce indică faptul că aceste strategii nu joacă un rol central în mecanismul analizat.
4. Relația dintre „Behavioral Disengagement” și „Stress” este predominant directă, iar acceptarea explică o mică parte din această relație. Acest lucru subliniază că există alte mecanisme psihologice sau contextuale care contribuie la reducerea stresului prin dezangajare comportamentală și care nu au fost incluse în acest model.

Aceste rezultate sugerează că strategia de coping prin acceptare este un mecanism relevant prin care „Behavioral Disengagement” influențează nivelul de stres. În schimb, alte strategii de coping precum „Active Coping,” „Positive Reframing,” și „Self-Distraction” nu au avut un impact semnificativ. Acest lucru evidențiază importanța focalizării pe strategiile de coping relevante în intervențiile psihologice, în special pe dezvoltarea acceptării ca modalitate de reducere a stresului.

4. Mediere secvențială - Modelul 6

1. Importați datele în SPSS.
2. Navigați la **Analyze > Regression > PROCESS v4.0 by Andrew F. Hayes.**
3. Selectați **Model 6** pentru analiza de mediere secvențială.
4. Definiți variabilele:
 - **X:** Variabila independentă.
 - **M1, M2 (etc.):** Mediatorii în succesiune.
 - **Y:** Variabila dependentă.
5. Configurați numărul de bootstrap pentru intervale de încredere robuste.
6. Rulați analiza.

Aceasta examinează relația dintre X și Y printr-o succesiune de mediatori, evaluând efectele indirecte secvențiale.

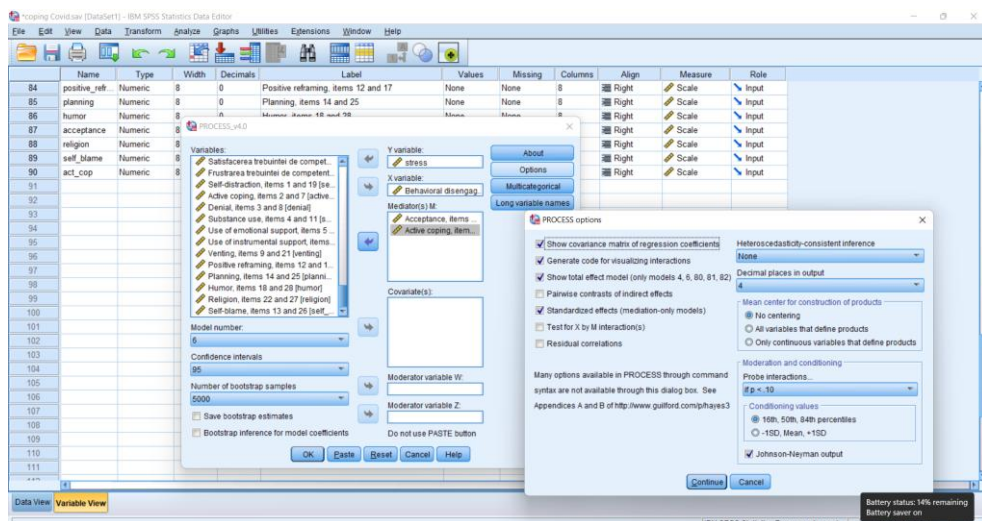


Figura 15. Interfața pentru analiza de mediere secvențială

În exemplul din Figura 15, ipoteza principală este că relația dintre „Behavioral Disengagement” (X) și „Stress” (Y) este mediată în mod secvențial prin intermediul a două variabile psihologice, fiecare reprezentând un mecanism distinct:

- **Mediator 1: „Acceptance” (M1):** Această variabilă reflectă gradul în care individul acceptă situațiile stresante, oferind o primă etapă de procesare psihologică a stresului. Acceptarea poate reduce tensiunea inițială și poate influența modul în care individul abordează situația.
- **Mediator 2: „Active Coping” (M2):** Această variabilă indică nivelul de implicare activă în gestionarea situațiilor stresante, reprezentând un răspuns comportamental adaptativ. Active coping este văzut ca o etapă ulterioară, în care acceptarea situației permite mobilizarea resurselor pentru a face față stresului în mod activ.

Modelul secvențial presupune că efectul lui „Behavioral Disengagement” asupra „Stress” este transmis în două etape: mai întâi prin acceptarea situației, iar ulterior prin implicarea activă în gestionarea acesteia.

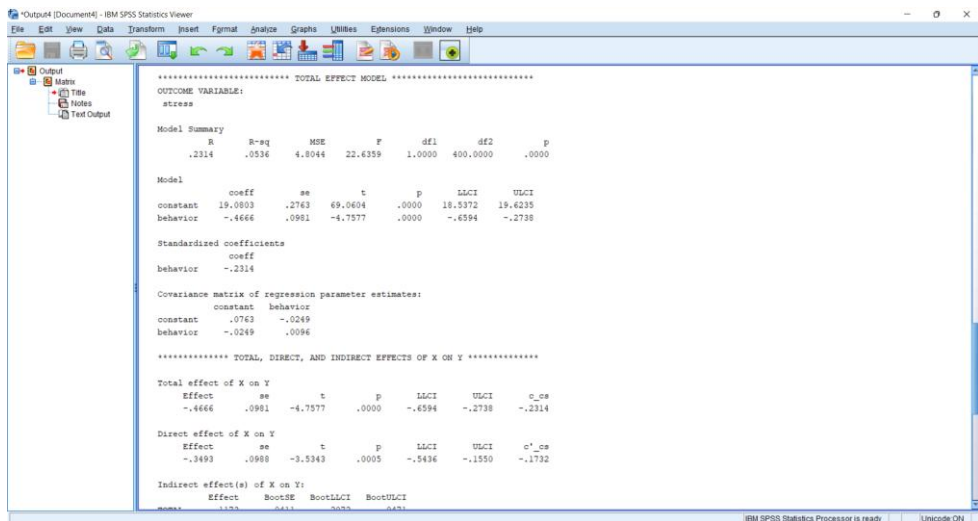


Figura 16. SPSS Output pentru analiza medierii secvențiale

Modelul analizează dacă relația dintre „Behavioral Disengagement” (X) și „Stress” (Y) este mediată de două variabile intermediare: „Acceptance” (M1) și „Active Coping” (M2). Mediarea este examinată atât pentru efectele individuale ale fiecărui mediator, cât și pentru contribuția lor în secvență.

1. Model pentru mediatorul 1: Acceptance

Acest model explorează relația dintre „Behavioral Disengagement” și „Acceptance” pentru a determina dacă dezangajarea comportamentală influențează gradul de acceptare al situațiilor stresante.

Rezumatul modelului:

- $R^2 = 0.0247$, $p = 0.0016$: Aproximativ 2.47% din variabilitatea lui „Acceptance” este explicată de „Behavioral Disengagement”. Modelul este semnificativ statistic, ceea ce sugerează o relație clară între aceste variabile.
- Coeficient ($b = -0.1773$, $p = 0.0016$): Relația dintre „Behavioral Disengagement” și „Acceptance” este semnificativă și negativă. Acest lucru indică faptul că, pe măsură ce nivelul de dezangajare comportamentală crește, nivelul de acceptare al situației scade.

Aceste rezultate sugerează că persoanele care adoptă o strategie de „Behavioral Disengagement” tind să accepte mai puțin situațiile stresante, ceea ce poate reduce capacitatea lor de a face față eficient acestor situații. Acceptarea, fiind un proces psihologic important pentru reglarea emoțiilor, poate fi diminuată atunci când indivizii evită în mod activ confruntarea cu stresul. Acest efect negativ asupra acceptării subliniază relevanța acestei variabile ca prim mecanism în procesul de mediere secvențială.

2. Model pentru mediatorul 2: Active Coping

Acest model examinează influența lui „Behavioral Disengagement” și „Acceptance” asupra „Active Coping”, oferind o perspectivă asupra modului în care aceste variabile contribuie la utilizarea strategiilor de gestionare activă a stresului.

Rezumatul modelului:

- $R^2 = 0.0882$, $p < 0.001$: Aproximativ 8.82% din variabilitatea lui „Active Coping” este explicată de „Behavioral Disengagement” și „Acceptance”. Modelul este semnificativ, ceea ce indică o contribuție semnificativă a predictorilor.
- Coeficienți:
- Behavioral Disengagement ($b = -0.4559$, $p < 0.001$): Relația este semnificativă și negativă. Acest lucru sugerează că persoanele care

adoptă dezangajarea comportamentală tind să utilizeze mai puțin strategiile de „Active Coping”.

- Acceptance ($b = 0.3685$, $p < 0.001$): Relația este semnificativă și pozitivă. Aceasta indică faptul că un nivel mai ridicat de acceptare crește probabilitatea utilizării strategiilor de „Active Coping”.

Rezultatele arată că „Behavioral Disengagement” și „Acceptance” influențează în mod opus utilizarea strategiilor de coping activ. Pe de o parte, „Behavioral Disengagement” reduce semnificativ implicarea activă, reflectând un stil de evitare. Pe de altă parte, „Acceptance” promovează adoptarea strategiilor de „Active Coping”, ceea ce sugerează că acceptarea situației permite o abordare mai constructivă și activă a problemelor.

3. Model pentru variabila dependentă: Stress

Acest model explorează influența directă a variabilelor „Behavioral Disengagement”, „Acceptance”, și „Active Coping” asupra nivelului de „Stress”, analizând contribuțiile fiecărui predictor la variabilitatea totală a stresului.

Rezumatul modelului:

- $R^2 = 0.1071$, $p < 0.001$: Aproximativ 10.71% din variabilitatea lui „Stress” este explicată de „Behavioral Disengagement”, „Acceptance”, și „Active Coping”. Modelul este semnificativ, indicând o relație puternică între acești predictorii și stres.
- Coeficienți:
- Behavioral Disengagement ($b = -0.3493$, $p < 0.001$): Relația este semnificativă și negativă. Aceasta indică faptul că dezangajarea comportamentală contribuie la reducerea stresului în mod direct, probabil prin evitarea confruntării cu factorii de stres.
- Acceptance ($b = 0.3011$, $p < 0.001$): Relația este semnificativă și pozitivă. Acest lucru sugerează că, pe măsură ce nivelul de acceptare crește, nivelul de stres raportat este, de asemenea, mai ridicat, ceea ce poate reflecta un mecanism în care acceptarea amplifică conștientizarea factorilor de stres.
- Active Coping ($b = 0.1227$, $p = 0.0064$): Relația este semnificativă și pozitivă. Rezultatele sugerează că utilizarea strategiilor de coping activ este asociată cu un nivel mai mare de stres, posibil datorită efortului și resurselor implicate în gestionarea activă a stresului.

Acest model evidențiază influențe contrastante asupra stresului:

- „Behavioral Disengagement” este asociat cu o reducere directă a stresului, subliniind că strategiile de evitare pot avea un efect temporar benefic prin diminuarea percepției stresului.
- În schimb, atât „Acceptance”, cât și „Active Coping” sunt asociate cu un stres mai ridicat. Acest rezultat poate reflecta un paradox al strategiilor de coping active și acceptare, în care confruntarea activă și conștientizarea situațiilor stresante pot duce la un nivel mai mare de tensiune percepută pe termen scurt.

4. Efectele totale, directe și indirecte

Efectul total:

- $b = -0.4666$, $p < 0.001$: Relația globală dintre „Behavioral Disengagement” și „Stress” este semnificativă și negativă. Acest rezultat indică faptul că utilizarea strategiei de dezangajare comportamentală reduce în mod general nivelul de stres, fără a lua în considerare mecanismele intermediare.

Efectul direct:

- $b = -0.3493$, $p < 0.001$: Chiar și după includerea mediatorilor „Acceptance” și „Active Coping”, relația directă dintre „Behavioral Disengagement” și „Stress” rămâne semnificativă. Acest rezultat sugerează că dezangajarea comportamentală influențează stresul și prin alte mecanisme decât cele captate de cei doi mediatori analizați.

Efectul total reflectă influența combinată a relației directe și a celor indirecte prin intermediul mediatorilor. Reducerea semnificativă a efectului direct față de efectul total sugerează că o parte din influența lui „Behavioral Disengagement” asupra „Stress” este transmisă prin mecanismele reprezentate de mediatori. Cu toate acestea, efectul direct rămâne semnificativ, indicând existența altor căi nereflectate de modelul propus.

Aceste rezultate evidențiază importanța „Behavioral Disengagement” ca strategie de coping, subliniind faptul că mecanismele psihologice mediate, precum „Acceptance” sau „Active Coping”, contribuie la relația dintre dezangajare comportamentală și stres, dar nu o explică în totalitate.

Efectele indirecte:

Efect	Coefficient (b)	BootSE	BootLLCI	BootULCI	Semnificație
Total indirect	-0.1173	0.0411	-0.2072	-0.0471	Semnificativ
Ind1 (acceptance)	-0.0534	0.0270	-0.1162	-0.0108	Semnificativ
Ind2 (active_coping)	-0.0559	0.0249	-0.1099	-0.0126	Semnificativ
Ind3 (secvențial: acceptance → active_coping)	-0.0080	0.0049	-0.0199	-0.0011	Semnificativ

Efectele indirecte:

- **Ind1 (Behavioral Disengagement → Acceptance → Stress):** Relația indirectă prin „Acceptance” este semnificativă. „Behavioral Disengagement” influențează „Stress” prin reducerea nivelului de „Acceptance”. Acest rezultat sugerează că dezangajarea comportamentală scade acceptarea situațiilor stresante, ceea ce, paradoxal, poate amplifica stresul.
- **Ind2 (Behavioral Disengagement → Active Coping → Stress):** Relația indirectă prin „Active Coping” este, de asemenea, semnificativă. „Behavioral Disengagement” reduce utilizarea strategiilor de „Active Coping”, iar acest lucru, la rândul său, crește nivelul de stres. Această relație subliniază impactul strategiilor active asupra percepției stresului.
- **Ind3 (Behavioral Disengagement → Acceptance → Active Coping → Stress):** Efectul indirect secvențial este mic, dar semnificativ. „Behavioral Disengagement” influențează „Stress” printr-un lanț causal care implică mai întâi „Acceptance” și apoi „Active Coping”.

Efectele globale:**1. Efectul total:**

- **b = -0.4666, p < 0.001:** Relația globală dintre „Behavioral Disengagement” și „Stress” este semnificativă și negativă. Acest rezultat indică faptul că, per ansamblu, utilizarea dezangajării comportamentale reduce nivelul de stres.

2. Contribuția mediatorilor:

- **„Acceptance”:** Acționează ca un mediator semnificativ, explicând o parte importantă din efectul total. Aceasta mediază efectul

dezangajării asupra stresului, dar creșterea acceptării este asociată cu un nivel mai mare de stres.

- **„Active Coping”**: Este, de asemenea, un mediator semnificativ, dar contribuția sa este mai mică decât a lui **„Acceptance”**. Aceasta sugerează că strategiile active pot amplifica stresul în anumite contexte.
- **Secvența Acceptance → Active Coping**: Contribuie la relația dintre **„Behavioral Disengagement”** și **„Stress”**, dar impactul său este mai redus în comparație cu celelalte efecte indirecte.

3. Efectul direct:

- **b = -0.3493, p < 0.001**: Relația directă dintre **„Behavioral Disengagement”** și **„Stress”** rămâne semnificativă. Acest rezultat indică faptul că dezangajarea comportamentală influențează stresul și prin alte mecanisme care nu sunt incluse în acest model.

Aceste rezultate evidențiază complexitatea relațiilor dintre strategiile de coping și stres:

- **„Acceptance”** are o influență duală: reduce efectele dezangajării, dar contribuie la creșterea stresului în mod direct.
- **„Active Coping”** mediază o parte din efectele lui **„Acceptance”** asupra stresului, dar impactul său este modest.
- Efectul direct semnificativ al **„Behavioral Disengagement”** asupra **„Stress”** sugerează că există mecanisme adiționale prin care această strategie de coping reduce stresul.

Acest model subliniază faptul că strategiile de coping pot avea efecte contradictorii în funcție de context și că este esențială înțelegerea acestor mecanisme pentru a dezvolta intervenții psihologice eficiente.

5. Mediere moderată - Modelele 7 și 8

1. Importați datele în SPSS.
2. Accesați **Analyze > Regression > PROCESS v4.0 by Andrew F. Hayes**.
3. Selectați:
 - **Model 7** pentru mediere moderată cu un moderator aplicat la relația dintre X și M.
 - **Model 8** pentru mediere moderată cu un moderator aplicat la relația dintre M și Y.
4. Specificați variabilele:

- **X**: Variabila independentă.
 - **M**: Mediatorul.
 - **W**: Moderatorul.
 - **Y**: Variabila dependentă.
5. Configurați setările bootstrap și intervalele de încredere.
 6. Rulați analiza.

Aceste modele evaluează efectele mediate și modul în care acestea sunt influențate de un moderator.

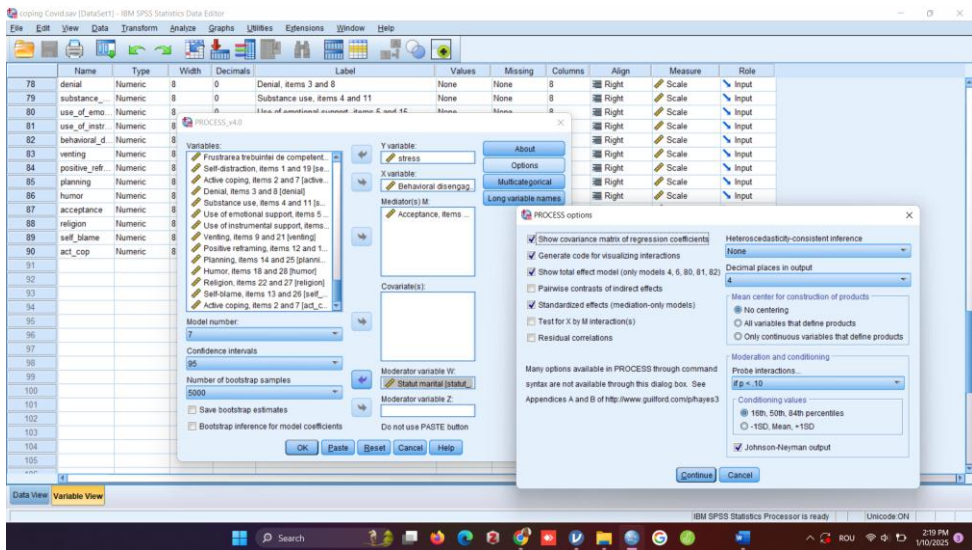


Figura 17. Interfața pentru mediere moderată cu un moderator aplicat la relația dintre X și M - Model 7

Interpretarea modelului moderat-mediat din Figura 17

În acest exemplu, relația dintre „Behavioral Disengagement” (X) și „Stress” (Y) este analizată printr-o combinație de mediere și moderare. „Acceptance” (M) este mediatorul, iar procesul de mediere este influențat de „Statut Marital” (W) ca variabilă moderatoare.

Ipoteze validate de model:

1. **Efectul direct al lui „Behavioral Disengagement” asupra „Stress”:**
 - Se așteaptă o relație negativă semnificativă între „Behavioral Disengagement” și „Stress”, indicând faptul că utilizarea strategiei de dezangajare comportamentală reduce stresul în mod direct.

2. Medierea prin „Acceptance”:

- Se presupune că „**Behavioral Disengagement**” influențează „**Acceptance**” într-un mod semnificativ negativ, ceea ce reduce capacitatea de acceptare a situațiilor. Această scădere a acceptării este ulterior asociată cu niveluri mai ridicate de stres.

3. Moderarea prin „Statut Marital”:

- Influența lui „**Behavioral Disengagement**” asupra „**Acceptance**” poate varia în funcție de statutul marital:
 - Pentru persoanele necăsătorite, se așteaptă ca dezangajarea comportamentală să aibă un impact mai mare asupra acceptării, deoarece lipsa suportului social poate amplifica efectele acestei strategii.
 - Pentru persoanele căsătorite, impactul poate fi mai redus, datorită rolului sprijinului social marital în compensarea efectelor negative ale dezangajării.

Rolul moderării în procesul de mediere:

Acest model sugerează că procesul de mediere dintre „**Behavioral Disengagement**” și „**Stress**” este condiționat de „**Statut Marital**”:

- La valori mai mici ale „**Statut Marital**” (de exemplu, persoane necăsătorite), efectul lui „**Behavioral Disengagement**” asupra „**Acceptance**” poate fi mai puternic, ceea ce sporește efectul indirect asupra stresului.
- La valori mai mari ale „**Statut Marital**” (de exemplu, persoane căsătorite sau căsătorite cu copii), acest efect poate fi atenuat, datorită rolului protector al suportului marital.

Implicarea teoretică:

Acest model combină avantajele analizei de mediere și moderare pentru a explica nu doar „dacă” există o relație între variabile, ci și „cum” și „în ce condiții” aceste relații au loc. Rezultatele oferă o perspectivă complexă asupra dinamicii copingului, acceptării și stresului, subliniind importanța contextului social (statutul marital) în influențarea procesului psihologic.

Implicarea practică:

Rezultatele pot ghida intervențiile psihologice și sociale:

- **Pentru persoanele necăsătorite:** Se pot dezvolta strategii de coping care să compenseze lipsa suportului social.
- **Pentru persoanele căsătorite:** Se pot accentua programele de sprijin marital pentru a reduce efectele negative ale dezangajării comportamentale.

Astfel, acest model oferă un cadru conceptual integrativ pentru a înțelege și interveni în relația complexă dintre coping și stres.

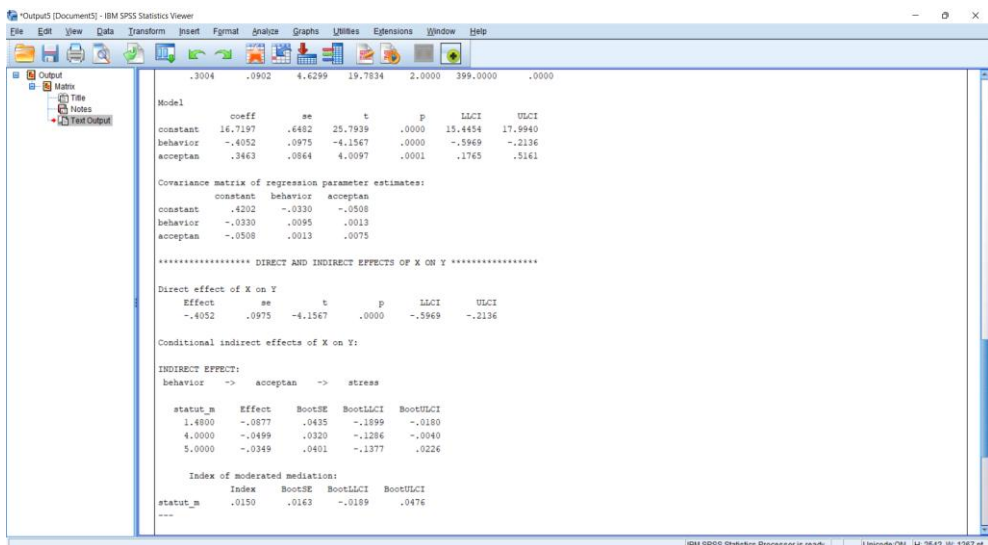


Figura 18. SPSS Output pentru analiza medierii moderate cu un moderator aplicat la relația dintre X și M - Model 7

Acest model integrează conceptele de mediere și moderare pentru a explora în profunzime dinamica relației dintre variabilele psihosociale. Testul analizează dacă efectul lui „Behavioral Disengagement” (X) asupra „Stress” (Y) este transmis prin intermediul mediatorului „Acceptance” (M) și dacă această transmisie variază în funcție de moderatorul „Statut Marital” (W).

1. Modelul pentru mediator (acceptance)

Acest model analizează dacă relația dintre „Behavioral Disengagement” și „Acceptance” este moderată de variabila „Statut Marital” (statut_m), prin includerea unui termen de interacțiune.

1. Proporția variabilității explicate (R²):

- Valoarea de R² = 0.0277 sugerează că aproximativ 2.77% din variabilitatea lui „Acceptance” este explicată de predictorii din model („Behavioral Disengagement”, „Statut Marital” și interacțiunea lor).
- Semnificația statistică globală (p = 0.0107) indică faptul că modelul este semnificativ în ansamblul său.

2. Termenul de interacțiune (Behavioral Disengagement × Statut Marital):

- Coeficientul termenului de interacțiune nu este semnificativ (p = 0.2649), ceea ce sugerează că relația dintre „Behavioral Disengagement” și „Acceptance” nu variază în funcție de nivelul statutului marital.

Coeficienți

Variabilă	Coeficient (b)	SE	t	p	LLCI	ULCI
Constant	7.1959	0.4024	17.8804	<0.001	6.4047	7.9871
Behavior	-0.3175	0.1374	-2.3101	0.0214	-0.5877	-0.0473
Statut_m	-0.1145	0.1097	-1.0436	0.2973	-0.3302	0.1012
Interacțiune (X×W)	0.0433	0.0388	1.1165	0.2649	-0.0330	0.1196

1. Efectul lui "Behavioral Disengagement" asupra "Acceptance":

- **Coeficient (b = -0.3175, p = 0.0214):** Rezultatele sugerează o relație semnificativă și negativă între "Behavioral Disengagement" și "Acceptance". Aceasta înseamnă că, pe măsură ce "Behavioral Disengagement" crește, nivelul de "Acceptance" scade. Este un efect semnificativ statistic (p < 0.05), ceea ce indică faptul că dezangajarea comportamentală este asociată cu o acceptare mai scăzută a situației.

2. Efectul "Statut_m" asupra "Acceptance":

- "Statut_m" nu are un efect semnificativ asupra "Acceptance". Coeficientul asociat cu statutul marital nu a fost semnificativ statistic,

cea ce sugerează că statutul marital nu influențează direct nivelul de acceptare.

3. Interacțiunea între "Behavioral Disengagement" și "Statut_m":

- Interacțiunea "Behavioral Disengagement" × "Statut_m" nu este semnificativă ($p = 0.2649$), ceea ce înseamnă că relația dintre "Behavioral Disengagement" și "Acceptance" nu variază în funcție de statutul marital. Acest rezultat sugerează că efectul dezangajării comportamentale asupra acceptării este similar pentru indivizi cu diferite statusuri matrimoniale.

2. Modelul pentru variabila dependentă (stress)

Acest model analizează efectele directe și indirecte ale "Behavioral Disengagement" și "Acceptance" asupra "Stress". Rezultatele obținute sunt prezentate mai jos:

- $R^2 = 0.0902$, $p < 0.001$: Aproape 9.02% din variabilitatea "Stress" este explicată de variabilele incluse în model ("Behavioral Disengagement" și "Acceptance"). Acesta este un model semnificativ statistic ($p < 0.001$), indicând faptul că, deși nu explică întreaga variabilitate a "Stress", modelul oferă o contribuție semnificativă în predicția nivelului de stres.

Coeficienți:

Variabilă	Coeficient (b)	SE	t	p	LLCI	ULCI
Constant	16.7197	0.6482	25.7939	<0.001	15.4454	17.9940
Behavior	-0.4052	0.0975	-4.1567	<0.001	-0.5969	-0.2136
Acceptance	0.3463	0.0864	4.0097	<0.001	0.1765	0.5161

Interpretare:

- "Behavioral disengagement" are un efect direct semnificativ și negativ asupra "stress" ($b = -0.4052$, $p < 0.001$). Acest rezultat sugerează că un nivel mai ridicat de "behavioral disengagement" (comportamente de evitare sau retragere) este asociat cu un nivel mai scăzut de "stress". Acest efect rămâne semnificativ chiar și atunci când sunt luate în considerare altele variabile de mediere sau moderare.
- "Acceptance" are un efect semnificativ și pozitiv asupra "stress" ($b = 0.3463$, $p < 0.001$). Aceasta sugerează că, pe măsură ce nivelul de

"**acceptance**" (acceptarea situațiilor stresante) crește, stresul perceput crește, indicând o relație directă și pozitivă între aceste variabile.

Efectele directe și indirecte

- Efect direct:
 - $b = -0.4052$, $p < 0.001$: Relația directă dintre "**behavioral disengagement**" și "**stress**" rămâne semnificativă, indicând că "**behavioral disengagement**" este un predictor semnificativ al "**stress**", chiar și după includerea altor variabile sau interacțiuni. Efectul negativ sugerează că un comportament de evitarea stresului poate reduce nivelul perceput de stres.
- În continuare, analiza efectelor indirecte va explora modul în care "**acceptance**" poate media această relație și ce impact are asupra "**stress**", având în vedere că "**acceptance**" ar putea influența modul în care "**behavioral disengagement**" afectează stresul.

Efecte indirecte condiționate de statutul marital:

Statut_m (percentile)	Efect indirect (b)	BootSE	BootLLCI	BootULCI	Semnificativ
1.4800 (16%)	-0.0877	0.0435	-0.1899	-0.0180	Da
4.0000 (50%)	-0.0499	0.0320	-0.1286	-0.0040	Da
5.0000 (84%)	-0.0349	0.0401	-0.1377	0.0226	Nu

Indexul medierii moderate:

Variabilă moderatoare	Index	BootSE	BootLLCI	BootULCI
statut_m	0.0150	0.0163	-0.0189	0.0476

Interpretare:

1. Efectul indirect al "**behavioral disengagement**" asupra "**stress**" prin "**acceptance**":
 - În cazul valorilor scăzute (1.4800) și medii (4.0000) ale "**statut marital**", efectul indirect al "**behavioral disengagement**" asupra "**stress**" prin "**acceptance**" este semnificativ. Acest lucru sugerează că, atunci când "**statut marital**" este la un nivel scăzut sau mediu (ex. persoane singure sau căsătorite fără copii), relația dintre "**behavioral disengagement**" și "**stress**" este mediată de "**acceptance**". Cu alte cuvinte, comportamentele de retragere pot

influența stresul prin reducerea gradului de "**acceptance**" al individului.

- Pentru **valori ridicate ale "statut marital"** (5.0000), efectul indirect devine **nesemnificativ**. Aceasta sugerează că, la persoanele căsătorite cu copii, "**acceptance**" nu mai joacă același rol de mediator în relația dintre "**behavioral disengagement**" și "**stress**", iar alte mecanisme ar putea fi implicate.

2. **Indexul medierii moderate:**

- Indexul medierii moderate (0.0150, CI [-0.0189, 0.0476]) nu este semnificativ, ceea ce indică faptul că moderarea de către "**statut marital**" nu este suficient de puternică pentru a influența în mod clar relația indirectă. Aceasta sugerează că, deși există o anumită variație a efectului în funcție de "**statut marital**", aceasta nu este consistentă sau suficient de pronunțată pentru a fi considerată un factor moderat semnificativ.

Rezumat:

1. **Relația dintre "behavioral disengagement" și "acceptance":**

- "**Behavioral disengagement**" reduce semnificativ "**acceptance**", indicând că retragerea comportamentală este asociată cu o capacitate mai mică de "**acceptance**" a situațiilor stresante.
- "**Statut marital**" nu influențează semnificativ această relație, iar interacțiunea dintre "**behavioral disengagement**" și "**statut marital**" nu este semnificativă. Acesta sugerează că "**statut marital**" nu joacă un rol important în modul în care comportamentele de evitare afectează "**acceptance**".

2. **Efectul lui "acceptance" asupra "stress":**

- "**Acceptance**" are un efect semnificativ pozitiv asupra "**stress**", sugerând că, în anumite contexte, "**acceptance**" poate amplifica percepția "**stresului**". Aceasta sugerează că persoanele care acceptă pasiv situațiile stresante pot trăi o intensificare a "**stresului**", ceea ce poate fi problematic pentru strategiile de coping.

3. **Moderarea prin "statut marital":**

- Efectul indirect al "**behavioral disengagement**" asupra "**stress**" este moderat doar **parțial** de "**statut marital**", fiind semnificativ pentru

valorile scăzute și medii ale "statut marital", dar nu pentru valorile ridicate.

- o Indexul medierii moderate nu este semnificativ, ceea ce indică o moderare slabă sau inconsistentă. Aceasta sugerează că "statut marital" nu influențează într-un mod clar relația indirectă dintre "behavioral disengagement" și "stress".

Aceste rezultate sugerează că, deși "statut marital" poate influența parțial relațiile dintre comportamentele de coping și "stress", "acceptance" joacă un rol semnificativ în acest proces de mediere. Totuși, interacțiunea moderatoare nu este consistentă, iar "acceptance" poate contribui la creșterea "stresului", subliniind importanța strategiilor de coping active pentru gestionarea eficientă a "stresului".

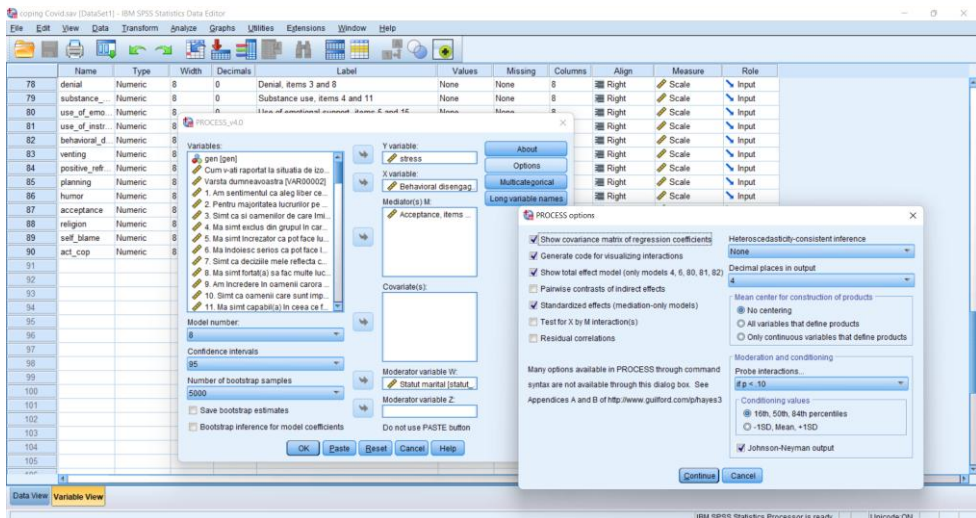


Figura 19. Interfața pentru mediere moderată cu un moderator aplicat la relația dintre M și Y – Model 8

În modelul prezentat în Figura 19, se testează ipoteza conform căreia relația dintre "behavioral disengagement" (X) și "stress" (Y) este mediată de "acceptance" (M), iar efectul lui "acceptance" asupra "stress" este moderat de "statut marital" (W). Spre deosebire de exemplele anterioare în care moderarea era analizată pe întreaga relație dintre "behavioral disengagement" și "stress", în acest model, moderarea este aplicată doar segmentului acceptance → stress. Cu alte cuvinte, "statut marital" este

presupus să influențeze modul în care "acceptance" afectează "stress", dar nu este un moderator direct între "behavioral disengagement" și "stress".

Această abordare permite o înțelegere mai nuanțată a modului în care statutul marital poate modula efectele "acceptance" asupra "stress". De exemplu, este posibil ca persoanele **singure** să răspundă diferit la acceptance în contextul "stress" comparativ cu persoanele **căsătorite** sau **căsătorite cu copii**, având în vedere factorii de sprijin social și responsabilitățile suplimentare care pot influența modul în care acceptarea contribuie la stres.

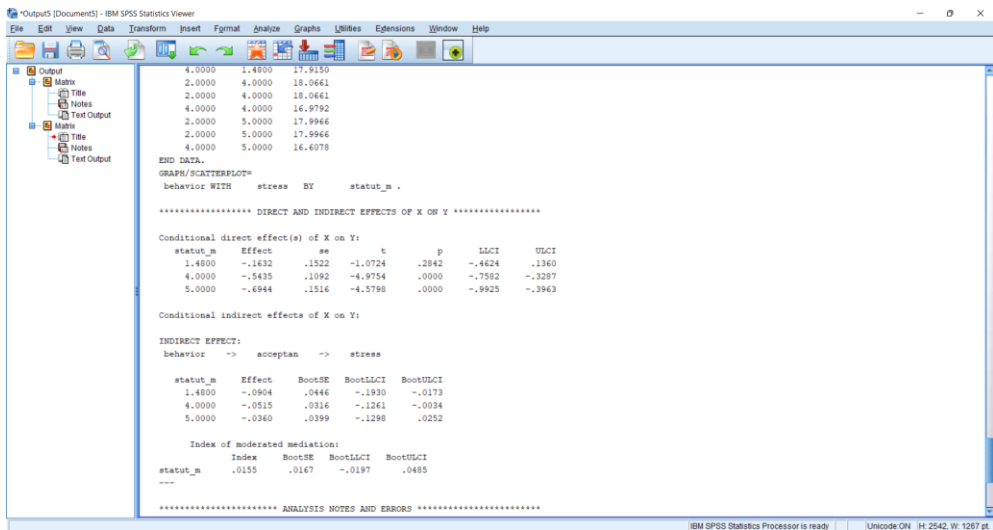


Figura 20. SPSS Output pentru analiza medierii moderate cu un moderator aplicat la relația dintre M și Y - Model 8

În acest model, se analizează efectul "behavioral disengagement" (X) asupra "stress" (Y), mediat de "acceptance" (M), și se examinează dacă efectul lui "acceptance" asupra "stress" este influențat de "statut marital" (W).

1. Modelul pentru mediatorul "acceptance":

o Rezumatul modelului:

- $R^2 = 0.0277$, $p = 0.0107$: Aproape 2.77% din variabilitatea "acceptance" este explicată de model, ceea ce sugerează că "behavioral disengagement" contribuie într-o măsură modestă la determinarea nivelului de "acceptance".
- Relația dintre "behavioral disengagement" și "acceptance" este semnificativă ($p = 0.0214$): Aceasta indică faptul că "behavioral

disengagement" are un efect semnificativ asupra "acceptance", ceea ce sugerează că persoanele care se angajează mai mult în comportamente de dezangajare pot avea mai mult dificultăți în a accepta situațiile stresante.

Aceste rezultate sugerează că "acceptance" joacă un rol important în procesul de mediere al relației dintre "behavioral disengagement" și "stress", iar "statut marital" va fi evaluat pentru a înțelege dacă moderează această relație.

Coefficienți:

Variabilă	Coefficient (b)	SE	t	p	LLCI	ULCI
Constant	7.1959	0.4024	17.8804	<0.001	6.4047	7.9871
Behavior	-0.3175	0.1374	-2.3101	0.0214	-0.5877	-0.0473
Statut marital	-0.1145	0.1097	-1.0436	0.2973	-0.3302	0.1012
Interacțiune (X × W)	0.0433	0.0388	1.1165	0.2649	-0.0330	0.1196

Interpretare

- „Behavioral disengagement” are un efect semnificativ negativ asupra „acceptance” ($b = -0.3175$, $p = 0.0214$). Aceasta înseamnă că, pe măsură ce „behavioral disengagement” crește, nivelul de „acceptance” scade. În mod specific, un comportament de „dezangajare comportamentală” mai pronunțat reduce capacitatea individului de a accepta situațiile stresante.
- „Statut marital” și interacțiunea dintre „behavioral disengagement” și „statut marital” nu au efecte semnificative asupra „acceptance”. Aceasta sugerează că „statutul marital” nu modifică semnificativ relația dintre „behavioral disengagement” și „acceptance”. În alte cuvinte, „statutul marital” nu joacă un rol moderant în modul în care „behavioral disengagement” influențează „acceptance”.

2. Modelul pentru variabila dependentă (stress)

Rezumatul modelului

- $R^2 = 0.1134$, $p < 0.001$: Aproximativ 11.34% din variabilitatea „stress” este explicată de model.

Coeficienți:

Variabilă	Coeficient (b)	SE	t	p	LLCI	ULCI
Constant	15.9549	0.9230	17.2862	<0.001	14.1404	17.7694
Behavior	0.0601	0.2363	0.2545	0.7992	-0.4044	0.5247
Acceptance	0.3569	0.0856	4.1689	<0.001	0.1886	0.5252
Statut marital	0.2323	0.1877	1.2376	0.2166	-0.1367	0.6012
Interacțiune (M × W)	-0.1509	0.0664	-2.2732	0.0235	-0.2814	-0.0204

Interpretare

- „Acceptance” are un efect semnificativ pozitiv asupra „stress” (b = 0.3569, p < 0.001), ceea ce sugerează că un nivel mai ridicat de acceptare este asociat cu un nivel mai ridicat de stres.
- Efectul lui „acceptance” asupra „stress” este influențat semnificativ de „statut marital” (b = -0.1509, p = 0.0235), indicând o moderare a efectului, ceea ce sugerează că efectul „acceptance” asupra „stress” variază în funcție de statutul marital.
- „Behavioral disengagement” nu are un efect direct semnificativ asupra „stress” (p = 0.7992), ceea ce sugerează că „behavioral disengagement” nu influențează în mod direct „stress” în acest model.

3. Testele de interacțiune și condiționare**Efecte condiționate (M → Y, moderate de statut marital)**

Statut marital (percentile)	Efect (b)	SE	t	p	LLCI	ULCI
1.4800 (16%)	-0.1632	0.1522	-1.0724	0.2842	-0.4624	0.1360
4.0000 (50%)	-0.5435	0.1092	-4.9754	<0.001	-0.7582	-0.3287
5.0000 (84%)	-0.6944	0.1516	-4.5798	<0.001	-0.9925	-0.3963

Interpretare:

- Pentru niveluri scăzute ale „statut marital” (1.4800), efectul indirect al „behavioral disengagement” asupra „stress” prin „acceptance” nu este semnificativ (p = 0.2842), indicând că, în cazul persoanelor singure, „acceptance” nu mediază relația dintre „behavioral disengagement” și „stress”.
- Pentru niveluri medii și ridicate ale „statut marital” (4.0000 și 5.0000), efectul indirect este semnificativ și negativ, ceea ce sugerează că „acceptance” reduce „stress” mai mult pentru persoanele căsătorite,

în special pentru cei care sunt căsătoriți cu copii. Acest lucru poate indica faptul că statutul marital, în special responsabilitățile familiale, modifică modul în care „**acceptance**” influențează „**stress**”.

Indexul medierii moderate

Variabilă moderatoare	Index	BootSE	BootLLCI	BootULCI
Statut marital	0.0155	0.0167	-0.0197	0.0485

- Indexul medierii moderate nu este semnificativ, deoarece intervalul de încredere include 0, ceea ce sugerează o moderare slabă sau inconsistență.

În acest model, rezultatele sugerează că „**behavioral disengagement**” influențează „**stress**” printr-o mediere semnificativă, în care „**acceptance**” joacă rolul de mediator. Astfel, un nivel mai ridicat de „**behavioral disengagement**” reduce „**acceptance**”, iar „**acceptance**”, la rândul său, crește „**stress**”. Mediatorul „**acceptance**” explică parțial relația dintre „**behavioral disengagement**” și „**stress**”, dar această mediere este influențată de „**statut marital**” doar pe segmentul „**acceptance** → **stress**”. Aceasta indică faptul că „**acceptance**” afectează nivelul de „**stress**” în mod diferit în funcție de statutul marital al individului. Efectul „**acceptance**” asupra „**stress**” este semnificativ mai puternic negativ pentru persoanele cu un „**statut marital**” stabil, adică pentru cei căsătoriți sau cei cu copii. Acest rezultat sugerează că în cazul acestora, „**acceptance**” are un impact mai mare asupra stresului, iar cei care nu sunt căsătoriți sau nu au copii experimentează o legătură mai slabă între „**acceptance**” și „**stress**”.

Capitolul de față a abordat în detaliu complexitatea relațiilor dintre variabilele psihosociale, utilizând modele avansate de mediere și moderare. Un accent deosebit a fost pus pe procesul de mediere moderată, care permite o înțelegere mai profundă a interacțiunilor complexe dintre comportamentele de coping, trăsăturile psihologice și condițiile contextuale. Prin utilizarea modelului PROCESS v4.0 în SPSS, am putut analiza nu doar efectele directe ale variabilelor, ci și mecanismele indirecte prin care acestea influențează rezultatele psihologice, punând în evidență condițiile în care aceste relații devin mai puternice sau mai slabe.

Modelele de mediere simplă au furnizat o înțelegere esențială a mecanismelor cauzale între variabilele independente, mediatori și variabilele dependente. Aceste modele au demonstrat că efectul unei variabile asupra altei variabile poate fi explicat, fie parțial, fie complet, prin intermediul unui mediator. De exemplu, în analiza comportamentelor de coping și stres, am observat că un mediator, precum acceptarea situației, poate explica modul în care strategiile de coping afectează nivelul de stres al indivizilor. Astfel, identificarea acestor mecanisme subiacente oferă o bază mai solidă pentru dezvoltarea intervențiilor care vizează reducerea stresului.

Modelele de mediere paralelă au extins această perspectivă, permițând includerea mai multor mediatori care acționează simultan, dar independent. Rezultatele acestor analize au subliniat complexitatea proceselor psihologice, arătând că nu există un singur mecanism care să explice complet efectele variabilelor independente asupra celor dependente. De exemplu, în analiza comportamentului de disengagement și stres, am observat că mai mulți mediatori contribuie în moduri distincte la relația dintre aceste variabile, ceea ce sugerează că factorii psihologici și sociali influențează simultan comportamentele și stările de bine ale indivizilor. Această abordare a fost esențială pentru a înțelege mai bine diversele influențe care formează comportamentele de coping și pentru a proiecta strategii de intervenție care să țină cont de multiplele dimensiuni ale aceleiași probleme.

Modelele de mediere secvențială au adus un plus de profunzime în analiza relațiilor dintre variabile. Aceste modele au arătat cum efectele unei variabile independente se propagă printr-un lanț de variabile intermediare, punând în evidență etapele succesive prin care influența psihologică se manifestă. Astfel, modelul secvențial a demonstrat că, deși influențele variabilelor independente sunt evidente în mod direct, ele sunt mediate de variabile intermediare într-o manieră complexă, care poate varia de la o etapă la alta.

Modelele de moderare au completat această analiză prin identificarea condițiilor în care relațiile dintre variabile se modifică. Acestea au demonstrat că variabilele de context, cum ar fi genul, statutul marital sau sprijinul social, pot amplifica sau atenua relațiile dintre factorii psihologici. De exemplu, am observat că statutul marital poate modula semnificativ efectele comportamentelor de coping asupra stresului. Astfel, persoanele căsătorite sau cu copii pot experimenta o relație mai slabă între strategiile de

coping și nivelul de stres, datorită suportului social disponibil, în timp ce persoanele singure pot fi mai sensibile la impactul acestor comportamente asupra stresului.

Modelele de mediere moderată au permis integrarea acestor concepte, oferind o viziune clară asupra modului în care mediul social și personal influențează procesul de mediere. Rezultatele au arătat că relațiile dintre comportamentele de coping și stres sunt influențate nu doar de variabilele psihologice, dar și de condițiile contextuale, cum ar fi statutul marital, care poate amplifica sau reduce efectele strategiilor de coping asupra stresului. De exemplu, în cadrul unui model avansat de mediere moderată, am identificat că, pentru persoanele căsătorite sau cu copii, acceptarea și strategiile de coping activ au un impact diferit asupra stresului decât în cazul celor singuri, ceea ce sugerează că sprijinul social poate juca un rol crucial în modul în care strategiile de coping influențează nivelul de stres.

În concluzie, modelele de mediere și moderare prezentate în acest capitol oferă o înțelegere detaliată a interacțiunilor complexe dintre variabilele psihosociale. Ele subliniază importanța identificării mecanismelor indirecte care explică relațiile dintre variabile și relevanța factorilor contextuali care pot modifica aceste relații. Această abordare oferă o bază solidă pentru intervențiile psihologice, educaționale și sociale, care pot fi adaptate nevoilor specifice ale diverselor grupuri demografice. Astfel, aceste analize contribuie la dezvoltarea unor intervenții personalizate care răspund provocărilor unice ale fiecărui individ sau grup social.

CAPITOLUL 8.

Interpretarea și prezentarea rezultatelor în cercetare

Interpretarea și prezentarea rezultatelor reprezintă o etapă esențială în procesul de cercetare științifică, în special în domeniul științelor sociale, unde analiza statistică este adesea utilizată pentru a valida ipotezele și pentru a oferi răspunsuri la întrebările de cercetare. Acest capitol detaliază structura unui raport statistic, standardele APA pentru raportarea rezultatelor și formularea concluziilor care integrează rezultatele în contextul cercetării.

8.1. Structura unui raport statistic: cum să organizezi și să interpretezi datele

Un raport statistic eficient constituie o etapă esențială în procesul de cercetare, având rolul de a organiza și de a comunica rezultatele într-un mod clar și coerent. Respectarea unei structuri logice facilitează interpretarea și înțelegerea datelor de către cititori, contribuind astfel la validarea concluziilor și la integrarea acestora în corpusul general al cunoștințelor științifice. Într-un raport statistic bine construit, fiecare secțiune își aduce propria contribuție la claritatea și relevanța analizei, asigurând totodată transparența procesului de cercetare. Structura standard a unui astfel de raport include introducerea, descrierea metodelor utilizate, prezentarea rezultatelor și interpretarea acestora în contextul întrebărilor și ipotezelor cercetării, culminând cu formularea unor concluzii bazate pe aceste rezultate (Field, 2018).

Introducerea rezultatelor are scopul de a stabili cadrul conceptual și metodologic al analizei statistice. Această secțiune se concentrează pe descrierea ipotezelor formulate și a tipurilor de analize aplicate pentru a

testa aceste ipoteze. De exemplu, utilizarea testelor t pentru comparația mediilor, a analizei ANOVA pentru evaluarea diferențelor între grupuri multiple sau a corelațiilor și modelelor de regresie pentru identificarea relațiilor dintre variabile constituie practici uzuale în cercetările din științele sociale. În cazul analizelor mai complexe, cum ar fi medierea sau moderarea, introducerea trebuie să descrie variabilele independente, mediatore și dependente, precum și eventualii moderatori. Această descriere contextualizează procesul analitic și oferă cititorilor o înțelegere clară a relațiilor investigate (Hayes, 2022).

Metodele statistice utilizate trebuie descrise în detaliu, punând accent pe instrumentele folosite și pe criteriile de selecție a datelor și modelelor. O documentare precisă a metodelor aplicate nu doar că sporește transparența, dar permite și replicarea cercetării de către alți autori. Raportarea detaliată include utilizarea metodelor de bootstrap pentru estimări robuste, aplicarea testelor de semnificație pentru validarea ipotezelor și măsurarea adecvării modelului prin indicatori specifici, precum R^2 , coeficienții ajustați sau valoarea F (Tabachnick & Fidell, 2019). Această secțiune trebuie să reflecte o abordare metodologică riguroasă, explicând criteriile statistice care stau la baza interpretării rezultatelor.

Prezentarea rezultatelor este un aspect central al raportului statistic, unde statistica descriptivă și inferențială sunt utilizate pentru a ilustra datele în mod clar și accesibil. Rezultatele trebuie să fie prezentate într-un mod concis, folosind tabele și grafice care facilitează înțelegerea relațiilor și a efectelor identificate. Informațiile esențiale, precum media (M), abaterea standard (SD), coeficienții statistici (β) și intervalele de încredere (CI), sunt incluse pentru a oferi cititorilor o imagine completă asupra datelor analizate. De exemplu, un tabel care arată relațiile dintre variabilele de interes poate evidenția coeficienții de corelație semnificativi, însoțiți de p-valori care confirmă semnificația statistică a acestor relații. Graficele, cum ar fi diagramele de regresie sau cele de interacțiune, oferă o reprezentare vizuală intuitivă a rezultatelor și contribuie la înțelegerea rapidă a datelor.

Interpretarea datelor reprezintă un alt pilon important al raportului statistic, unde rezultatele brute sunt contextualizate în raport cu întrebările de cercetare și ipotezele formulate. Este esențial ca analiza statistică să fie integrată în cadrul teoretic al studiului, explicând implicațiile practice și teoretice ale coeficienților semnificativi. De exemplu, dacă un coeficient

semnificativ sugerează o relație pozitivă între utilizarea strategiilor de coping activ și reducerea stresului, această constatare trebuie discutată în contextul literaturii existente și al aplicabilității practice în intervențiile psihologice. Interpretările trebuie să fie argumentate și să reflecte complexitatea relațiilor dintre variabile, oferind o bază solidă pentru concluzii și recomandări.

Un raport statistic bine structurat și detaliat nu doar că sprijină validitatea cercetării, dar contribuie și la diseminarea rezultatelor într-un mod accesibil și util. Claritatea în descrierea ipotezelor, precizia în raportarea metodelor, concizia în prezentarea rezultatelor și coerența în interpretarea acestora sunt aspecte esențiale pentru a asigura relevanța științifică și aplicabilitatea practică a oricărei cercetări. În acest mod, raportul statistic devine un instrument puternic pentru avansarea cunoașterii în domeniul științelor sociale și pentru susținerea intervențiilor bazate pe dovezi.

8.2. Raportarea corectă a statisticilor în științele sociale (standarde APA)

Conform manualului APA (American Psychological Association, 2020), raportarea statisticilor în științele sociale trebuie să urmeze standarde clare și bine definite pentru a asigura transparența procesului de cercetare și replicabilitatea rezultatelor. Aceste standarde sunt esențiale pentru validarea concluziilor și pentru integrarea lor în corpul general al cunoașterii științifice. O raportare corectă și completă nu doar că facilitează înțelegerea rezultatelor de către cititori, ci contribuie și la consolidarea credibilității cercetării.

Raportarea descriptivă reprezintă primul pas în prezentarea statisticilor, oferind o imagine de ansamblu asupra caracteristicilor variabilelor analizate. Valorile mediei și ale abaterii standard sunt esențiale pentru a descrie distribuția datelor și pentru a oferi context interpretării ulterioare. De exemplu, raportarea valorilor descriptive precum „Nivelul mediu al stresului a fost de 4.56 (SD = 1.23)” permite cititorilor să înțeleagă variația și tendințele generale din cadrul eșantionului studiat. Aceste informații sunt fundamentale pentru a contextualiza rezultatele inferențiale și pentru a înțelege mai bine specificitatea populației analizate.

În ceea ce privește testele statistice, raportarea acestora trebuie să fie detaliată și să includă toate informațiile relevante, precum valoarea statisticii, gradele de libertate și p-valoarea asociată. De exemplu, în cazul unui test ANOVA, raportarea corectă ar putea fi exprimată astfel: „ $F(2, 98) = 3.45, p = .035$ ”. Acest nivel de detaliu asigură o înțelegere completă a testului aplicat și a semnificației rezultatelor. În analiza unor modele mai complexe, cum sunt cele de mediere și moderare, intervalele de încredere bootstrap devin obligatorii, deoarece oferă o estimare robustă a efectelor indirecte și condiționate, reducând riscul de interpretări eronate (Hayes, 2022).

Vizualizarea rezultatelor reprezintă un instrument esențial pentru a traduce datele complexe într-un format clar și intuitiv. Graficele și tabelele facilitează înțelegerea relațiilor dintre variabile și ilustrează vizual efectele descoperite în cadrul analizei. De exemplu, diagramele Johnson-Neyman sunt deosebit de utile pentru a prezenta efectele condiționate în modelele de moderare, indicând clar intervalele în care relațiile dintre variabile sunt semnificative. Acest tip de reprezentare vizuală sporește accesibilitatea rezultatelor, făcându-le relevante pentru o audiență mai largă și contribuind la claritatea raportului statistic.

Precizia și replicabilitatea sunt esențiale în orice cercetare științifică. Raportarea numărului de observații (N), a metodelor de eșantionare și a presupunerilor utilizate în cadrul modelului statistic contribuie la transparența analizei. Aceste detalii permit cititorilor să evalueze validitatea și generalizabilitatea rezultatelor, oferind totodată informații care facilitează replicarea studiilor. Spre exemplu, precizarea metodei de eșantionare și a criteriilor de incluziune a participanților ajută la interpretarea rezultatelor și la înțelegerea limitărilor cercetării (Field, 2018).

Raportarea statisticilor conform standardelor APA garantează nu doar o prezentare clară și transparentă a datelor, ci și integrarea acestora într-un cadru teoretic și metodologic solid. Aceste standarde asigură validitatea concluziilor și oferă o bază de încredere pentru aplicațiile practice și cercetările viitoare, contribuind astfel la avansarea cunoștințelor în domeniul științelor sociale.

8.3. Formularea concluziilor și utilizarea rezultatelor în contextul cercetării

Concluziile reprezintă un moment central al oricărui demers științific, integrând rezultatele statistice într-un cadru conceptual care răspunde întrebărilor de cercetare și contribuie la extinderea literaturii de specialitate. Nu este suficient ca aceste concluzii să se limiteze la o simplă raportare a efectelor identificate; ele trebuie să explice relevanța acestor efecte, să ofere implicații teoretice și practice și să evidențieze direcții viitoare pentru cercetare. În acest sens, concluziile devin o punte între analiza statistică și aplicabilitatea rezultatelor, susținând astfel progresul în domeniul psihologiei și al altor științe sociale conexe.

Legarea rezultatelor de întrebările de cercetare este un pas esențial în formularea concluziilor, întrucât acestea trebuie să răspundă în mod direct ipotezelor formulate la începutul studiului. De exemplu, dacă ipoteza cercetării sugerează că acceptarea mediază relația dintre comportamentul de coping și stres, concluziile ar trebui să confirme sau să infirme această legătură, pe baza datelor analizate. O formulare specifică ar putea fi: „Rezultatele noastre susțin ipoteza că acceptarea mediază relația dintre comportamentul de coping și stres, cu un efect condiționat de statutul marital”. Această claritate în legarea rezultatelor de ipoteze contribuie la coerența raportului de cercetare și facilitează înțelegerea impactului descoperirilor.

Implicările practice ale rezultatelor trebuie analizate și comunicate în concluzii, oferind recomandări care pot ghida intervențiile sau politicile. De exemplu, dacă un studiu identifică un efect semnificativ al genului asupra stresului, concluziile ar putea sugera dezvoltarea unor strategii diferențiate de intervenție psihologică care să răspundă nevoilor specifice ale bărbaților și femeilor. În același mod, în cazul în care statutul marital moderează efectul unei strategii de coping asupra stresului, intervențiile ar putea fi adaptate pentru a include sprijin social mai mare pentru persoanele singure sau divorțate. Aceste aplicații practice sunt fundamentale pentru a transforma descoperirile științifice în soluții concrete pentru provocările întâlnite în diverse contexte sociale (Tabachnick & Fidell, 2019).

Discutarea limitărilor cercetării este o componentă vitală a concluziilor, subliniind transparența și onestitatea cercetătorului. Limitările pot fi legate de eșantion, metode de colectare a datelor sau constrângeri ale modelelor statistice utilizate. De exemplu, o limitare obișnuită ar putea fi

utilizarea unui eșantion omogen, care restricționează generalizarea rezultatelor. În mod similar, presupunerile modelelor statistice, cum ar fi liniaritatea sau independența observațiilor, pot influența interpretarea rezultatelor. Discutarea acestor aspecte nu doar că întărește credibilitatea studiului, dar oferă și un cadru pentru îmbunătățiri în cercetările viitoare. Sugestiile pentru direcții viitoare pot include extinderea studiului la eșantioane mai diverse, aplicarea unor modele statistice mai complexe sau explorarea unor variabile suplimentare care ar putea influența relațiile studiate.

Concluziile nu reprezintă doar o încheiere a procesului de cercetare, ci și un punct de plecare pentru investigații viitoare. Ele oferă un rezumat al contribuției studiului, clarificând modul în care descoperirile susțin sau extind literatura existentă și evidențiind utilitatea practică a rezultatelor. Prin integrarea riguroasă a datelor statistice, analiza implicațiilor și discutarea limitărilor, concluziile contribuie la avansarea cunoașterii și la dezvoltarea unor intervenții eficiente, adaptate nevoilor diverse ale indivizilor și comunităților. Acest demers sistematic și bine fundamentat asigură relevanța cercetării și replicabilitatea.

Bibliografie

1. Agler, R., & De Boeck, P. (2017). On the interpretation and use of mediation: Multiple perspectives on mediation analysis. *Frontiers in psychology*, 8, 1984.
2. Aiken, L. S., West, S. G., Pitts, S. C., Baraldi, A. N., & Wurpts, I. C. (2012). Multiple linear regression. *Handbook of Psychology*, Second Edition, 2.
3. Aiken, L. S., West, S. G., Sechrest, L., Reno, R. R., Roediger III, H. L., Scarr, S., ... & Sherman, S. J. (1990). Graduate training in statistics, methodology, and measurement in psychology: A survey of PhD programs in North America. *American Psychologist*, 45(6), 721.
4. American Psychological Association. (2020). *Publication manual of the American Psychological Association* (7th ed.). Washington, DC: Author.
5. Andersen, P. K., & Skovgaard, L. T. (2010). *Regression with linear predictors*. Springer.
6. Andreeva, T., & Kianto, A. (2011). Knowledge processes, knowledge-intensity and innovation: a moderated mediation analysis. *Journal of knowledge management*, 15(6), 1016-1034.
7. Andrews, D. F. (1974). A robust method for multiple linear regression. *Technometrics*, 16(4), 523-531.
8. Arlinghaus, S. (Ed.). (2020). *Practical handbook of spatial statistics*. CRC press.
9. Arndt, S., Turvey, C., & Andreasen, N. C. (1999). Correlating and predicting psychiatric symptom ratings: Spearman's r versus Kendalls tau correlation. *Journal of psychiatric research*, 33(2), 97-104.

10. Bangdiwala, S. I. (2018). Regression: simple linear. *International journal of injury control and safety promotion*, 25(1), 113-115.
11. Barber, J., & Thompson, S. (2004). Multiple regression of cost data: use of generalised linear models. *Journal of health services research & policy*, 9(4), 197-204.
12. Berk, K. N., & Booth, D. E. (1995). Seeing a curve in multiple regression. *Technometrics*, 37(4), 385-398.
13. Bharadwaj, S., Khan, N. A., & Yameen, M. (2022). Unbundling employer branding, job satisfaction, organizational identification and employee retention: a sequential mediation analysis. *Asia-Pacific Journal of Business Administration*, 14(3), 309-334.
14. Bishara, A. J., & Hittner, J. B. (2012). Testing the significance of a correlation with nonnormal data: comparison of Pearson, Spearman, transformation, and resampling approaches. *Psychological methods*, 17(3), 399.
15. Boon, M. H., & Thomson, H. (2021). The effect direction plot revisited: application of the 2019 Cochrane Handbook guidance on alternative synthesis methods. *Research synthesis methods*, 12(1), 29-33.
16. Borradaile, G., & Borradaile, G. (2003). Regression: Linear, Curvilinear and Multilinear. *Statistics of Earth Science Data: Their Distribution in Time, Space, and Orientation*, 133-156.
17. Breiman, L., & Friedman, J. H. (1997). Predicting multivariate responses in multiple linear regression. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 59(1), 3-54.
18. Bunford, N., Evans, S. W., Becker, S. P., & Langberg, J. M. (2015). Attention-deficit/hyperactivity disorder and social skills in youth: A moderated mediation model of emotion dysregulation and depression. *Journal of abnormal child psychology*, 43, 283-296.
19. Charalambous, A., Giannakopoulou, M., Bozas, E., & Paikousis, L. (2019). Parallel and serial mediation analysis between pain, anxiety, depression, fatigue and nausea, vomiting and retching within a randomised controlled trial in patients with breast and prostate cancer. *BMJ open*, 9(1), e026809.

20. Chase, L. J., & Chase, R. B. (1976). A statistical power analysis of applied psychological research. *Journal of Applied Psychology*, 61(2), 234.
21. Chughtai, M. S., & Khan, H. S. U. D. (2024). Knowledge oriented leadership and employees' innovative performance: a moderated mediation model. *Current Psychology*, 43(4), 3426-3439.
22. Chughtai, M. S., & Khan, H. S. U. D. (2024). Knowledge oriented leadership and employees' innovative performance: a moderated mediation model. *Current Psychology*, 43(4), 3426-3439.
23. Coetzee, S., & Merwe, P. V. D. (2010). Industrial psychology students' attitudes towards statistics. *SA Journal of Industrial Psychology*, 36(1), 1-8.
24. Cortina, J. M. (1993). Interaction, nonlinearity, and multicollinearity: Implications for multiple regression. *Journal of management*, 19(4), 915-922.
25. Cowles, M. (2005). *Statistics in psychology: An historical perspective*. Psychology Press.
26. Crewson, P. (2006). *Applied statistics handbook*. AcaStat Software, 1, 103-123.
27. Cuc, L. D., Feher, A., Cuc, P. N., Szentesi, S. G., Rad, D., Rad, G., ... & Joldes, C. S. R. (2022). A parallel mediation analysis on the effects of pandemic accentuated occupational stress on hospitality industry staff turnover intentions in COVID-19 context. *International Journal of Environmental Research and Public Health*, 19(19), 12050.
28. Dashti, S. G., Viallon, V., Simpson, J. A., Karahalios, A., Moreno-Betancur, M., English, D. R., ... & Murphy, N. (2020). Explaining the link between adiposity and colorectal cancer risk in men and postmenopausal women in the UK Biobank: a sequential causal mediation analysis. *International Journal of Cancer*, 147(7), 1881-1894.
29. Del Águila, M. R., & Benítez-Parejo, N. (2011). Simple linear and multivariate regression models. *Allergologia et immunopathologia*, 39(3), 159-173.
30. Dicke, T., Parker, P. D., Marsh, H. W., Kunter, M., Schmeck, A., & Leutner, D. (2014). Self-efficacy in classroom management, classroom

- disturbances, and emotional exhaustion: A moderated mediation analysis of teacher candidates. *Journal of educational psychology*, 106(2), 569.
31. Dughi, T., Rad, D., Runcan, R., Chiș, R., Vancu, G., Maier, R., ... & Mihaela, M. C. (2023). A Network Analysis-Driven Sequential Mediation Analysis of Students' Perceived Classroom Comfort and Perceived Faculty Support on the Relationship between Teachers' Cognitive Presence and Students' Grit—A Holistic Learning Approach. *Behavioral Sciences*, 13(2), 147.
 32. Eberly, L. E. (2007). Correlation and simple linear regression. *Topics in biostatistics*, 143-164.
 33. Einarsen, S., Skogstad, A., Rørvik, E., Lande, Å. B., & Nielsen, M. B. (2018). Climate for conflict management, exposure to workplace bullying and work engagement: a moderated mediation analysis. *The International Journal of Human Resource Management*, 29(3), 549-570.
 34. Field, A. (2018). *Discovering statistics using IBM SPSS statistics* (5th ed.). Sage.
 35. Fredricks, G. A., & Nelsen, R. B. (2007). On the relationship between Spearman's rho and Kendall's tau for pairs of continuous random variables. *Journal of statistical planning and inference*, 137(7), 2143-2150.
 36. Gana, M., Rad, D., & Stoian, C. D. (2023). Family functioning, parental attachment and students' academic success. *Journal of Infrastructure, Policy and Development*, 8(1), 2565.
 37. Ganzach, Y. (1997). Misleading interaction and curvilinear terms. *Psychological methods*, 2(3), 235.
 38. Gaylor, D. W., & Sweeny, H. C. (1965). Design for optimal prediction in simple linear regression. *Journal of the American Statistical Association*, 60(309), 205-216.
 39. Gordon, R. A. (2012). *Applied statistics for the social and health sciences*. Routledge.
 40. Gripengberg, G. (1992). Confidence intervals for partial rank correlations. *Journal of the American Statistical Association*, 87(418), 546-551.

41. Hanley, J. A. (2016). Simple and multiple linear regression: sample size considerations. *Journal of clinical epidemiology*, 79, 112-119.
42. Hayes, A. F. (2009). Beyond Baron and Kenny: Statistical mediation analysis in the new millennium. *Communication monographs*, 76(4), 408-420.
43. Hayes, A. F. (2022). *Introduction to mediation, moderation, and conditional process analysis: A regression-based approach* (3rd ed.). Guilford Press.
44. Hayes, A. F., & Preacher, K. J. (2014). Statistical mediation analysis with a multicategorical independent variable. *British journal of mathematical and statistical psychology*, 67(3), 451-470.
45. Hooi Ting, D. (2004). Service quality and satisfaction perceptions: curvilinear and interaction effect. *International Journal of Bank Marketing*, 22(6), 407-420.
46. Hope, T. M. (2020). Linear regression. In *Machine learning* (pp. 67-81). Academic Press.
47. Howitt, D., & Cramer, D. (2008). *Introduction to statistics in psychology*. Pearson education.
48. Iacobucci, D. (2008). *Mediation analysis* (No. 156). Sage.
49. Iki, K., Sato, S., & Tomizawa, S. (2018). Decomposition of Parsimonious Independence Model Using Pearson, Kendall and Spearman's Correlations for Two-Way Contingency Tables. *International Journal of Statistics and Probability*, 7(3), 105.
50. James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). Linear regression. In *An introduction to statistical learning: With applications in python* (pp. 69-134). Cham: Springer International Publishing.
51. Jobson, J. D., & Jobson, J. D. (1991). Multiple linear regression. *Applied multivariate data analysis: regression and experimental design*, 219-398.
52. Jokić, B., Ristić Dedić, Z., & Šimon, J. (2024). Time spent using digital technology, loneliness, and well-being among three cohorts of

- adolescent girls and boys—a moderated mediation analysis. *Psihologijske teme*, 33(1), 25-46.
53. Kane, L., & Ashbaugh, A. R. (2017). Simple and parallel mediation: A tutorial exploring anxiety sensitivity, sensation seeking, and gender. *The quantitative methods for psychology*, 13(3), 148-165.
 54. Kelley, K., & Bolin, J. H. (2013). Multiple regression. In *Handbook of quantitative methods for educational research* (pp. 69-101). Brill.
 55. Kendall, M. G. (1942). Partial rank correlation. *Biometrika*, 32(3/4), 277-283.
 56. Kondrič, M., Trajkovski, B., Strbad, M., Foretić, N., & Zenić, N. (2013). Anthropometric influence on physical fitness among preschool children: gender-specific linear and curvilinear regression models. *Collegium antropologicum*, 37(4), 1245-1252.
 57. Krieger, A. M., Pollak, M., & Yakir, B. (2003). Surveillance of a simple linear regression. *Journal of the American Statistical Association*, 98(462), 456-469.
 58. Krzywinski, M., & Altman, N. (2015). Multiple linear regression: when multiple variables are associated with a response, the interpretation of a prediction equation is seldom simple. *Nature methods*, 12(12), 1103-1105.
 59. Lalonde, R. N., & Gardner, R. C. (1993). Statistics as a second language? A model for predicting performance in psychology students. *Canadian Journal of Behavioural Science/Revue canadienne des sciences du comportement*, 25(1), 108.
 60. Lawless, K. A., & Kulikowich, J. M. (2006). Domain knowledge and individual interest: The effects of academic level and specialization in statistics and psychology. *Contemporary Educational Psychology*, 31(1), 30-43.
 61. Liu, Q., Li, C., Wang, V., & Shepherd, B. E. (2018). Covariate-adjusted Spearman's rank correlation with probability-scale residuals. *Biometrics*, 74(2), 595-605.
 62. Lu, D., Zhang, L., Wang, X., & Song, L. (2018). Some new measures of dependence for random variables based on Spearman's ρ and Kendall's τ . *Journal of Nonparametric Statistics*, 30(4), 860-883.

63. MacKinnon, D. (2012). *Introduction to statistical mediation analysis*. Routledge.
64. Macklin, J. T. (1982). An investigation of the properties of double radio sources using the Spearman partial rank correlation coefficient. *Monthly Notices of the Royal Astronomical Society*, 199(4), 1119-1136.
65. Malibari, M. A., & Bajaba, S. (2022). Entrepreneurial leadership and employees' innovative behavior: A sequential mediation analysis of innovation climate and employees' intellectual agility. *Journal of Innovation & Knowledge*, 7(4), 100255.
66. Marill, K. A. (2004). Advanced statistics: linear regression, part I: simple linear regression. *Academic emergency medicine*, 11(1), 87-93.
67. Marill, K. A. (2004). Advanced statistics: linear regression, part II: multiple linear regression. *Academic emergency medicine*, 11(1), 94-102.
68. Maulud, D., & Abdulazeez, A. M. (2020). A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(2), 140-147.
69. Memon, M. A., Jun, H. C., Ting, H., & Francis, C. W. (2018). Mediation analysis issues and recommendations. *Journal of applied structural equation modeling*, 2(1), i-ix.
70. Miot, H. A. (2018). Correlation analysis in clinical and experimental studies. *Jornal vascular brasileiro*, 17, 275-279.
71. Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis*. John Wiley & Sons.
72. Moran, P. A. P. (1951). Partial and multiple rank correlation. *Biometrika*, 38(1/2), 26-32.
73. Nimon, K. F., & Oswald, F. L. (2013). Understanding the results of multiple linear regression: Beyond standardized regression coefficients. *Organizational Research Methods*, 16(4), 650-674.
74. Nisbet, R., Elder, J., & Miner, G. D. (2009). *Handbook of statistical analysis and data mining applications*. Academic press.

75. Norouzian, R., & Plonsky, L. (2018). Correlation and simple linear regression in applied linguistics. *The Palgrave handbook of applied linguistics research methodology*, 395-421.
76. Obilor, E. I., & Amadi, E. C. (2018). Test for significance of Pearson's correlation coefficient. *International Journal of Innovative Mathematics, Statistics & Energy Policies*, 6(1), 11-23.
77. Opara, K. R., & Hryniewicz, O. (2016). Computation of general correlation coefficients for interval data. *International Journal of Approximate Reasoning*, 73, 56-75.
78. Pantea, M. F., Cilan, T. F., Cuc, L. D., Rad, D., Bâtcă-Dumitru, G. C., Șendroi, C., ... & Gomoi, B. C. (2024). Optimizing Romanian Managerial Accounting Practices through Digital Technologies: A Resource-Based and Technology-Deterministic Approach to Sustainable Accounting. *Electronics*, 13(16), 3206.
79. Pek, J., & Hoyle, R. H. (2016). On the (in) validity of tests of simple mediation: Threats and solutions. *Social and personality psychology compass*, 10(3), 150-163.
80. Pham, H. (Ed.). (2023). *Springer handbook of engineering statistics*. Springer Nature.
81. Pituch, K. A., & Stevens, J. P. (2015). *Applied multivariate statistics for the social sciences: Analyses with SAS and IBM's SPSS*. Routledge.
82. Privitera, G. J. (2023). *Statistics for the behavioral sciences*. Sage publications.
83. Puth, M. T., Neuhäuser, M., & Ruxton, G. D. (2015). Effective use of Spearman's and Kendall's correlation coefficients for association between two measured traits. *Animal Behaviour*, 102, 77-84.
84. Racine, J., Su, L., & Ullah, A. (Eds.). (2014). *The Oxford handbook of applied nonparametric and semiparametric econometrics and statistics*. Oxford University Press, USA.
85. Rad, D., & Demeter, E. (2020). A moderated mediation effect of online time spent on internet content awareness, perceived online hate speech and helping attitudes disposal of bystanders. *Postmodern Openings*, 11(2 Supl 1), 107-124.

86. Redeş, A., Rad, D., Roman, A., Bocoş, M., Chiş, O., Langa, C., ... & Baci, C. (2023). The Effect of the Organizational Climate on the Integrative–Qualitative Intentional Behavior in Romanian Preschool Education—A Top-Down Perspective. *Behavioral Sciences*, 13(4), 342.
87. Rijnhart, J. J., Twisk, J. W., Eekhout, I., & Heymans, M. W. (2019). Comparison of logistic-regression based methods for simple mediation analysis with a dichotomous outcome variable. *BMC medical research methodology*, 19, 1-10.
88. Rodrigues, A. C. (2021). Response surface analysis: A tutorial for examining linear and curvilinear effects. *Revista de Administração Contemporânea*, 25(06), e200293.
89. Rosa, J. C. D., Aleman, J. O., Mohabir, J., Liang, Y., Breslow, J. L., & Holt, P. R. (2022). The application of spearman partial correlation for screening predictors of weight loss in a multiomics dataset. *OMICS: A Journal of Integrative Biology*, 26(12), 660-670.
90. Roth, P. L. (1994). Missing data: A conceptual review for applied psychologists. *Personnel psychology*, 47(3), 537-560.
91. Rucker, D. D., Preacher, K. J., Tormala, Z. L., & Petty, R. E. (2011). Mediation analysis in social psychology: Current practices and new recommendations. *Social and personality psychology compass*, 5(6), 359-371.
92. Sachs, L. (2012). *Applied statistics: a handbook of techniques*. Springer Science & Business Media.
93. Sawyer, R. K. (Ed.). (2005). *The Cambridge handbook of the learning sciences*. Cambridge University Press.
94. Sedgwick, P. (2013). Simple linear regression. *BMJ*, 346.
95. Shelleby, E. C., Votruba-Drzal, E., Shaw, D. S., Dishion, T. J., Wilson, M. N., & Gardner, F. (2014). Income and children's behavioral functioning: A sequential mediation analysis. *Journal of Family Psychology*, 28(6), 936.
96. Shi, R., & Conrad, S. A. (2009). Correlation and regression analysis. *Ann Allergy Asthma Immunol*, 103(4), S34-S41.

97. Slinker, B. K., & Glantz, S. A. (1988). Multiple linear regression is a useful alternative to traditional analyses of variance. *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, 255(3), R353-R367.
98. Stevens, J. (2002). *Applied multivariate statistics for the social sciences* (Vol. 4). Mahwah, NJ: Lawrence Erlbaum Associates.
99. Swanzy, E. K. (2020). The impact of supervisor support on employees' psychological wellbeing: A parallel mediation analysis of work-to-family conflict and job satisfaction. *International business research*, 13(11), 41-53.
100. Tabachnick, B. G., & Fidell, L. S. (2019). *Using multivariate statistics* (7th ed.). Pearson.
101. Timm, N. H. (1975). *Multivariate analysis with applications in education and psychology* (pp. 444-450). Monterey, California: Brooks/Cole Publishing Company.
102. Tinsley, H. E., & Brown, S. D. (Eds.). (2000). *Handbook of applied multivariate statistics and mathematical modeling*. Academic press.
103. Tranmer, M., & Elliot, M. (2008). Multiple linear regression. *The Cathie Marsh Centre for Census and Survey Research (CCSR)*, 5(5), 1-5.
104. Uyanık, G. K., & Güler, N. (2013). A study on multiple linear regression analysis. *Procedia-Social and Behavioral Sciences*, 106, 234-240.
105. Williams, R. B. G. (1986). Spearman's and Kendall's Coefficients of Rank Correlation. In *Intermediate Statistics for Geographers and Earth Scientists* (pp. 451-479). Palgrave, London.
106. Xuan, W., Williams, K., & Peat, J. K. (2020). *Health science research: A handbook of quantitative methods*. Routledge.
107. Zou, K. H., Tuncali, K., & Silverman, S. G. (2003). Correlation and simple linear regression. *Radiology*, 227(3), 617-628.



ISBN 978-606-37-2506-7