

„Analiza riscului în evaluarea oportunităților internaționale de investiții. Perspective în modelarea și previzionarea volatilității utilizate în estimarea riscului”¹

Marius Matei, student doctorand la ESADE Business School, Departamentul de Finanțe, Barcelona și la Institutul Național de Cercetări Economice „Costin C. Kirițescu”, al Academiei Române²

Abstract: Teza își propune să evalueze riscul în contextul deciziilor de investire în străinătate. Pentru identificarea categoriilor de risc, s-a folosit drept criteriu raportul dintre conținutul de endogeneitate și cel de exogeneitate al acestora. În grupa riscurilor endogene atenția a fost concentrată asupra riscului de credit, riscului asumat (de contrapartidă) și a riscului sistemic; s-a evidențiat totodată rolul agențiilor internaționale de rating în determinarea costului creditului și în ultimă instanță în determinarea succesului emisiunilor de titluri făcute în scopul asigurării surselor financiare necesare finanțării proiectelor de investiții. În grupa riscurilor exogene a fost identificat riscul asimilat fluctuației randamentelor date de variația prețurilor acțiunilor. Această fluctuantă a fost denumită „volatilitate” și a fost evaluată din punct de vedere econometric. A fost sugerat faptul că cea mai bună modalitate de a evalua riscul unui sector este de a forma un portofoliu/grup de acțiuni aparținând celor mai relevante companii activând în același sector, și de a modela și previziona volatilitatea randamentelor portofoliului astfel creat. Problema devine complicată din cauza subiectivității în alegerea modelului de previzionare a volatilității, care provine din lipsa existenței unui consens în literatură în ceea ce privește identificarea unui model capabil să calculeze cei mai buni estimatori. Mai mult, din moment ce considerăm un portofoliu cu serii puternic corelate, un model multivariat trebuie aplicat, fapt ce determină ca problema să fie extrem de dificil de rezolvat empiric. Am sugerat ca pentru portofoliile formate din sute și mii de variabile, Principal Component-GARCH este modelul potrivit de utilizat pentru previzionarea volatilității. Calitățile modelului PC-GARCH sunt puse în valoare din perspectiva raportului calitate/cost oferit de acesta în raport cu orice model alternativ, și au fost identificate ca fiind: capacitatea acestuia de minimizare a eforturilor computaționale (prin transformarea modelelor multivariate GARCH în modele univariate), prin reducerea semnificativă a timpului computațional și eliminarea oricărei probleme ce se poate ivi din manipulări complexe de date, asigurarea unui control strict al cantității de „zgomot” prin reducerea numărului de variabile la un număr mai mic de componente principale și îmbunătățirea performanțelor unui model GARCH simplu prin obținerea de inovații total independente.

¹ Prezentul articol reprezintă rezumatul tezei de doctorat elaborate la Institutul Național de Cercetări Economice „Costin C. Kirițescu” al Academiei Române, sub coordonarea Prof. Univ. Dr. Mircea Ciumara.

² Adrese de contact: marius.matei76@gmail.com, marius.matei@esade.edu

Cuvinte cheie: risc, endogeneitate, exogeneitate, riscul de credit, riscul sistemic, volatilitate, heteroskedasticitate, GARCH, previziuni, corelații, cost, ortogonalitate, componente principale.

A. Introducere

Teza își propune să evalueze riscul în contextul deciziilor de investire în străinătate. Când companiile decid să investească într-o altă țară, ele își gândesc investiția fie ca una de tip green-field (pornită de la zero), fie ca o achiziție a unei companii locale. Termenul de risc acoperă o varietate largă de concepte, începând de la riscul sistemic sau cel de credit până la cel reputațional, operațional sau politic, a căror abordare necesită o analiză preponderent calitativă, deseori împrumutând teorii sau concepte din domenii conexe precum economia, politica sau managementul. Riscurile ce afectează o companie care investește în străinătate pot fi clasificate în diverse modalități, folosind diferite criterii. Un studiu riguros al întregului ansamblu de concepte de risc ar necesita un spațiu extrem de larg, dincolo de cel standard al unei lucrări doctorale. Date fiind limitările de spațiu ce se impun unei astfel de teze, în scopul răspunderii adecvate întrebărilor de cercetare menținând în același timp rigurozitatea și abstractizarea unei lucrări de cercetare, am restrâns aria de analiză de la una foarte generală la doar două aspecte (consider, cele mai importante) ale riscului.

În identificarea acestora, am divizat riscurile în două categorii, folosind drept criteriu raportul dintre conținutul de endogeneitate și cel de exogeneitate a riscurilor. Astfel, am identificat o categorie endogenă de riscuri pe care o companie le poate influența prin acțiuni proprii și o categorie de riscuri exogene pe care compania nu le poate controla deloc, dar pe care le poate evalua și împotriva cărora poate elabora strategii de apărare (eventual scenarii de ieșire din piață).

În fiecare categorie am identificat un singur tip de risc, cel mai important din categoria căreia îi aparține. Pentru riscurile endogene, a fost ales riscul de credit (în forma sa extinsă riscul asumat sau de contrapartidă). Când o companie decide să investească într-o țară străină, accesul la surse de finanțare locale este esențial în implementarea proiectelor de investiții, pentru menținerea și dezvoltarea afacerii în general. Finanțarea afacerii poate depinde atât de aspecte exclusiv endogene, precum profitabilitatea companiei pusă în evidență prin indicatori de performanță precum ROE, ROA etc., dar și de aspecte exogene precum promptitudinea cu care companiile aflate în relații de afaceri cu firma respectivă își plătesc la timp propriile obligații financiare. Problemele financiare ale altor companii se pot astfel transfera de la o companie la alta, iar amploarea și viteza cu care acest lucru se întâmplă pot determina dificultăți serioase, mergând până la falimente. Astfel, modul în care sistemul de plăți între companii este construit sau administrat, precum și expunerea la riscul sistemic pot determina performanța oricărei companii sau investiții a acesteia într-o anumită piață.

De asemenea, dacă compania decide să se autofinanțeze nu doar prin reinvestirea profitului sau prin acces la credite bancare, dar prin emisiuni de titluri, ratingurile de țară sau cele acordate companiei însăși de către agențiile internaționale de rating pot afecta determinant costul creditului și în ultimă instanță succesul emisiunii de titluri. În acest context, se evaluează nu doar performanțele companiei, dar și cele ale economiei naționale. Astfel, problema accesului la surse de credit devine parțial endogenă și parțial exogenă. Fiind vorba de un concept mai larg decât al unei simple performanțe financiare, consider că endogeneitatea domină și astfel am denumit această categorie de risc drept endogenă.

Cealaltă jumătate a problemei implică riscul sectorului în care compania urmează să activeze. Înainte de investire, compania va evalua riscul pe care prezența pe o anumită piață îl comportă prin formarea unui portofoliu de companii cu cea mai mare pondere în sectorul respectiv. Spre exemplu, dacă compania noastră activează în sectorul IT din Franța și dorește să investească în sectorul IT din Statele Unite, putem investiga riscul căderii pieței de IT din Statele Unite, mai ales în contextul existenței unei bule de preț (așa cum de altfel s-a întâmplat și în trecut). Succesul companiei nu implică astfel doar managementul unui departament anume sau al echipei de conducere, ci poate fi o variabilă cu factori localizați exclusiv în perimetrul pieței, mai ales atunci când există riscul unei evoluții negative accentuate a acesteia. În condițiile apariției unui astfel de eveniment, indiferent de performanța companiei, randamentul acțiunilor acesteia va fi în mod serios afectat. Evaluarea probabilității ca astfel de căderi ale pieței să aibe loc devine o problemă de măsurare și previzionare a volatilității randamentelor acțiunilor companiilor selectate în portofoliu, cu contribuție semnificativă la evoluția pieței din care acestea fac parte. Dacă varianța acestui portofoliu va fi largă, sau dacă va fi redusă dar se poate documenta existența unei probabilități mari de creștere a acesteia în viitorul imediat, dat fiind faptul că investitorii evită riscul, investiția într-o astfel de piață nu este, probabil, o idee foarte bună.

Oportunitatea investiției se transformă astfel într-o problemă econometrică de previzionare a volatilității. Discuția se complică ca urmare a mai multor factori, dintre care cei mai importanți sunt următorii:

1. Lumea științifică nu a ajuns încă la un consens în privința superiorității unui model sau grup de modele anume care măsoară volatilitatea. Astfel, previziunile diferă în funcție de modelul cu care au fost realizate; mai mult, variațiile între acestea sunt suficient de mari încât desemnarea unui model anume drept cel mai performant să fie dificilă. Există diferențe între clasamentele care încearcă să identifice cel mai bun model de previzionare a volatilității și datorită altor factori: metodologiile folosite, utilizarea de date cu frecvență mare sau redusă, sursa datelor, orizontul pe care se face predicția, selecția formulelor de calcul al erorilor etc. Astfel, decizia legată de oportunitatea investiției va depinde și de alegerile econometrice ce urmează a fi făcute în desfășurarea exercițiului empiric.
2. Pentru o acuratețe sporită în măsurarea riscului, compania nu va evalua randamentele doar ale unui singur tip de acțiuni, ci pe cele ale unui portofoliu format din randamentele mai multor tipuri de acțiuni (cele aparținând companiilor relevante din sector). Astfel, analiza se transformă dintr-o problemă de măsurare univariată a

volatilității într-una de măsurare multivariată a volatilității. Aceasta complică foarte mult problema cel puțin din două motive: modelele multivariate ce ar trebui să fie folosite ar trebui să elimine corelațiile dintre seriile de timp luate în considerare (de exemplu, dacă portofoliul este format din doi indecși de preț, NASDAQ și S&P 500, modelul trebuie să elimine corelațiile dintre datele istorice ale indexului S&P 500 cu cele ale NASDAQ, deoarece o variație ce a avut loc într-un index de preț poate să fi determinat o variație similară în celălalt index, astfel că informațiile din portofoliul format din S&P și NASDAQ pot fi dublate). Astfel, problemele multivariate devin intensive din punct de vedere computațional din cauza problemei estimării parametrilor. De exemplu, numărul parametrilor dintr-un model multivariat GARCH crește la o rată egală cu pătratul numărului de variabile incluse în model. Folosind n variabile independente va necesita estimarea unui număr de $\frac{n(n+1)}{2}$ parametri; aceasta se întâmplă deoarece fiecare variabilă adițională aduce cu ea termenii de corelație cu celelalte variabile, și fiecare dintre acești termeni de corelație va avea parametrul propriu. Dimensionalitatea problemei, și prin urmare necesitatea puterii computaționale, devin semnificative.

Ca o soluție la ambele probleme, voi argumenta superioritatea unui model heteroskedastic autoregresiv (PC-GARCH), considerând nu doar performanța exprimată prin acuratețea previziunilor calculate, dar și componenta de cost (costul de timp și logistic necesar obținerii unui anumit nivel de acuratețe a previziunilor). Pentru acest scop, voi dezvolta în ultima parte a tezei un exercițiu empiric cu un portofoliu format din șapte acțiuni aparținând sectorului IT american (Adobe, Apple, Autodesk, Cisco, Dell, Microsoft și 3M) care vor fi folosite în scopul evidențierii calităților acestui model. Astfel, voi concluziona faptul că atunci când se lucrează cu sute sau mii de variabile, în scopul previzionării volatilității (și deci a riscului), PC-GARCH este cel mai potrivit model de a fi utilizat.

Întrebările cărora cercetarea de față va încerca să le răspundă sunt:

1. Care sunt cele mai importante aspecte ale riscului atunci când o companie dorește să investească în străinătate?
2. Cum poate fi optimizat managementul riscului de credit?
3. Cum poate fi optimizată modelarea volatilității atunci când se lucrează cu portofolii mari de acțiuni?

Voi concluziona partea introductivă prin menționarea elementelor care constituie noutatea acestei cercetări:

1. Primul element de noutate este reprezentat de o analiză integrată a riscului de credit, a riscului sistemic și a problemei evaluării volatilității făcute în scopul determinării riscului asociat investițiilor desfășurate în străinătate.
2. Al doilea element de noutate este comparația modelelor de previzionare a volatilității. Deși studii similare au existat, cercetarea curentă ia în considerație și articole publicate mai recent. De asemenea, un element de noutate este reprezentat de sinteza

extinsă a literaturii, pusă sub forma unui tabel ce conține cele mai importante 50 de articole scrise pe subiectul clasificării modelelor de volatilitate.

3. Analiza modelelor de previzionare a volatilității dintr-o perspectiva dublă, aceea a acurateții estimărilor și a costurilor implicate, conform căreia superioritatea modelului PC-GARCH a fost concluzionată, reprezintă un alt element de noutate.
4. Adaptarea unei tehnici propuse de Alexander (2000) pentru Analiza Componentelor Principale la o metodă Orthogonal GARCH propusă de Burns (2005).
5. În final, exercițiul empiric cu un portofoliu format din șapte acțiuni activând în sectorul american de IT, este un alt element de noutate.

B. Grupa riscurilor endogene. Riscul de credit și sistemic. Agențiile de rating

Un instrument financiar poate lua mai multe forme: numerar, dovezi de proprietate asupra unei acțiuni sau datorii, un contract de tip „futures”, o opțiune sau pur și simplu un contract care conține obligații și drepturi ale părților semnatare. Prin tranzacțiile cu aceste instrumente, participanții la astfel de activități se expun unei palete largi de riscuri, printre care riscurile de credit și cele de piață sunt cele mai importante. Prin intermediul acestor instrumente, companiile dobândesc resurse financiare ce pot fi folosite la dezvoltarea proiectelor de investiții.

Riscul de credit reprezintă riscul ca cealaltă parte angajată într-o tranzacție ce are ca subiect un instrument financiar să eșueze în a-și onora termenii angajamentelor contractuale, ca urmare a unor probleme precum lipsa de lichidități, falimentul etc. În termeni tehnici, riscul de credit se bazează pe evaluarea probabilității de intrare în incapacitate de plată a participanților la acte de afaceri. O astfel de analiză este în general întreprinsă de agențiile de rating care clasifică probabilitatea de intrare în incapacitate de plată, conform unei scale de risc. Întrucât riscul de credit este comun tuturor tranzacțiilor sau entităților de afaceri, iar ponderea acestuia între celelalte tipuri endogene de risc este dominantă, analiza care stă la baza primei părți a tezei de doctorat este concentrată în special asupra acestui tip de risc. Deoarece o companie, când se decide să investească într-o altă țară, nu este conștientă de cele mai multe ori de capacitatea firmelor locale de a-și îndeplini obligațiile financiare, rolul în evaluarea acestor capacități va reveni aproape exclusiv agențiilor de rating. Întrucât lipsa capacității de onorare a unei obligații financiare a unei companii se poate transmite și altor companii cu care se află în relații contractuale, expunerea unei economii, sector economic sau companii la riscul sistemic ar putea fi de interes de asemenea pentru noul intrat pe piață. Pentru acest motiv au fost discutate în teză deopotrivă riscul sistemic și rolul agențiilor de credit.

Riscul asumat (*'counterparty risk'*) este un tip de risc de credit ce merge dincolo de eșecul financiar (reprezentat exclusiv de riscul de credit) și include, printre alte lucruri, întârzieri în execuții cauzate fie de partenerul însuși sau de mediul financiar în care operează, fie de lipsa dorinței de execuție a obligațiilor, ceea ce conduce la riscul reputațional. În versiunea sa extinsă, riscul asumat este probabilitatea de survenire a unei pierderi ca urmare a eșecului celeilalte părți de a își duce tranzacția la bun sfârșit conform termenilor contractuali, ca

urmare a unor condiții adverse. Sursa acestui risc poate fi găsită în politica managerială de respectare a termenelor de plată, în riscul apariției unui eveniment, sau în alte motive. Riscul de credit își are originea în faptul că produsele și instrumentele care sunt implicate într-o tranzacție impun nu doar drepturi, ci și obligații, pe când riscul asumat implică criterii adiționale legate de obligațiile financiare.

În prima sa parte, teza tratează conceptul de risc în general și evoluția sa de-a lungul timpului, în contextul globalizării. Treptat, atenția se restrânge la riscul de credit, cu extensiile acestuia – riscul asumat și riscul sistemic. Dobândirea de noi sensuri ale conceptului de risc a reprezentat factorul cel mai semnificativ ce a stat la baza schimbărilor survenite în sistemul financiar. În mod tradițional, evaluarea capacității de rambursare a unui împrumut a constituit subiect de analiză doar atunci când potențialul contractant de credit lua decizia luării unui astfel de împrumut. Până recent, evaluarea acestei capacități era responsabilitatea doar a departamentelor de credit ale băncilor, care aveau un număr relativ mic de clienți și suficiente resurse de evaluare detaliată a capacităților financiare ale solicitanților. Dezvoltarea piețelor financiare a atribuit analiștilor de credite sarcini mai complexe care au îmbogățit paleta lor de responsabilități, cerându-le acum să lucreze cu un manager instituțional de portofoliu sau uneori cu o agenție independentă de evaluare a riscului de credit. Evaluarea riscului nu mai este făcută doar la momentul contractării unui credit, ci permanent.

Secțiunea dedicată riscurilor endogene începe printr-o prezentare a fundamentelor riscului de credit în contextul creșterii în amploare a piețelor de capital pe care sunt lansate de cele mai multe ori ofertele de obligațiuni în vederea finanțării proiectelor de investiții. Evoluția piețelor financiare poate fi sintetizată prin prisma dinamicii distincte a trei fenomene: desintermedierea (reducerea ponderii și intensității relațiilor de intermediere bancară), securitizarea creditării bancare și globalizarea piețelor financiare. Din punct de vedere istoric, cei mai importanți intermediari între deținătorii de capital și utilizatorii acestuia au fost băncile. Principalele lor funcții erau să colecteze fonduri de la primii (sub forma depozitelor) și să le ofere (prin creditare) celor din urmă (companii, instituții publice, guverne). Acestei simple funcții i s-au adăugat de-a lungul timpului activități precum intermedierea în piețele de capital. Ca urmare, s-a observat o creștere globală constantă a piețelor de capital și a numărului emitenților de titluri de valoare. Utilizatorii de capital care își finanțau anterior activitățile exclusiv prin credite bancare, au dobândit astfel acces la o sursă mai largă de finanțare pe termen scurt. Utilizarea tot mai largă a acestor instrumente descrie procesul de desintermediere. Câteva avantaje pot explica apariția unei astfel de proces. Din perspectiva contractantului de împrumut, ieșirea din sistemul strict bancar, fie în piețele de obligațiuni, fie în cele de titluri comerciale, poate reprezenta o reducere de cost substanțială. Pe lângă acesta, ratele dobânzii sunt mai competitive în astfel de piețe deschise, deoarece cumpărătorii le vor putea alege pe cele mai economice dintr-o paletă largă de surse interne sau internaționale, decât apelând la o selecție formată din câteva bănci. Din perspectiva emitentului, împrumutul acordat direct în piața de capital poate aduce avantaje cum ar fi faptul că o parte din economisirea realizată de investitori poate fi transmisă emitenților sub forma unor dobânzi superioare celor bancare. De asemenea, investițiile în titlurile comerciale sunt de obicei mai flexibile decât împrumuturile pe termen scurt de la bănci.

Securitizarea completează desintermedierea. Odată cu renunțarea la creditele bancare, companiile au început să emită titluri de valoare pe care le vând direct în piețele de capital. Astfel, banii ce înainte erau împrumutați de la bănci, acum se obțin prin intermediul acestor instrumente. Acest fenomen descrie securitizarea crescândă a împrumuturilor.

Securitizarea și desintermedierea au condus la globalizarea piețelor de credit. În acest context, dată fiind eterogenitatea nivelurilor de dezvoltare a piețelor naționale de capital, rolul agențiilor independente de rating a fost văzut drept unicul instrument de a ajuta investitorii în efectuarea unor evaluări corecte ale oportunităților de investiții, existând un consens în ceea ce privește rolul acestora de a promova o creștere continuă și stabilitate în piețele de capital, domestice sau internaționale.

Așadar, deși multă vreme rolul băncilor în obținerea resurselor financiare era asimilat unui monopol, treptat ponderea acestora în ansamblul surselor de creditare s-a diminuat, pe fondul unei diversificări a serviciilor oferite. Întrucât companiile au apelat tot mai des la propriile emisiuni de titluri în vederea obținerii de resurse financiare, ca alternativă mai ieftină la creditele bancare, un capitol a fost rezervat dezbaterii acestui subiect. Astfel, o arie mai largă de alegeri ce pot fi făcute între mai multe surse de finanțare, se traduce într-o capacitate mai robustă de finanțare în piețe cu rate ale dobânzilor mai mici. Ea oferă totodată posibilitatea emitenților să vândă în cantități, frecvențe, țări, monede și structuri de maturitate care corespund cel mai bine nevoilor lor de finanțare. La nivel global, cel mai important avantaj ce decurge din apelarea la emisiuni de titluri este diversificarea: aceasta reprezintă abilitatea de plasare a investițiilor în mai multe portofolii în jurul lumii cu efect în reducerea riscului suportat de investitori. Astfel, emitenții vor dobândi capacitatea de a alege dintr-o gamă largă de oportunități de investiții, într-o piață globală a posibilităților de finanțare, o flexibilitate ce devine din ce în ce mai mult un element critic de profitabilitate în piețele globale tot mai competitive.

Au fost discutate în continuare relațiile cu creditorii prin prisma oportunităților și riscurilor existente la momentul emisiunilor de titluri. S-au discutat astfel motivele ce au condus la decizia avansării proiectelor de emisiuni de titluri, caracteristicile emitenților globali de astfel de titluri și caracteristicile relațiilor contractuale stabilite cu investitorii în acest tip de instrument. De asemenea, au fost discutate riscurile cu care se confruntă emitenții de titluri, în contextul diminuării datoriei publice (lipsită de risc), al reducerii rolului măsurilor guvernamentale de securizare a acestor instrumente, în contextul unei creșteri globale a riscurilor în piețele financiare. Alte aspecte discutate: ciclul creditului ca un efect al vulnerabilizării sistemului financiar, efectul proliferării emitenților de calitate redusă (cu risc crescut de nerăscumpărare a titlurilor), globalizarea piețelor financiare, riscurile asociate proceselor de consolidare și structurilor corporaționale complexe, riscurile tehnologice și de mediu, legate de mediul legislativ și de structura de reglementări națională și internațională, riscurile politice.

Următorul capitol a fost dedicat riscului sistemic. Unul dintre aspectele omniprezente ale mediului financiar contemporan este rețeaua amplă de interconexiuni ce există între companii. Deși, în teoria economică, datoriile unei companii către o altă companie sunt de

obicei modelate unidirecțional, precum obligații dependente numai de sănătatea financiară a companiei emitente, în realitate, structura contabilă a obligațiilor unei companii este mult mai complexă. Valoarea celor mai multe companii este dependentă de plățile ce sunt încasate ca urmare a stingerii unor datorii ale altor firme către compania creditoare. Valoarea acestor sume de încasat depinde, astfel, de sănătatea financiară a altor companii din sistem. Mai mult, legăturile dintre companii pot fi ciclice. Incapacitatea de plată de către firma A a unor datorii către firma B poate conduce la neplata obligațiilor pe care firma B le are către firma C. Incapacitatea de plată ce poate afecta firma C, în schimb, se poate răsfrânge asupra capacității de plată a firmei A. Acest exemplu ilustrează o caracteristică generală a arhitecturii sistemului financiar care poartă numele în teoria financiară de „interdependență ciclică”. O bună parte din articolele scrise pe această temă se ocupă de gasirea unui mecanism de autoreglare atunci când această interdependență este prezentă. *Riscul sistemic* reprezintă propagarea dificultăților financiare ale unui agent economic către alți agenți economici legați de acel agent prin tranzacții financiare.

Capitolul dedicat riscului sistemic începe prin definirea conceptului de risc sistemic, identificând efectele adverse pe care acesta le presupune, și îl plasează în contextul relațiilor interbancare, prin intermediul cărora de cele mai multe ori se propagă. În această perspectivă, reglementările bancare sunt esențiale, un sub-capitol fiind dedicat acestora și rolului lor în oprirea propagării riscului.

Urmează o scurtă trecere în revistă a evenimentelor în care riscul sistemic s-a manifestat de-a lungul timpului. Am identificat elementele care indică o expunere potențială la acest tip de risc, de asemenea aspectele sub care riscul s-a manifestat. În acest context, perioada de dinainte de 1988 și cea de după (marcată de adoptarea Regulamentelor Basel I și Basel II) apar distincte, ca urmare a modului prin care riscul sistemic a fost abordat. Prevenția riscului sistemic și administrarea acestuia odată ce acesta apare sunt următoarele două capitole. Secțiunea dedicată riscului sistemic se încheie cu concluzii.

Așa cum s-a menționat anterior, eterogenitatea nivelurilor de dezvoltare a piețelor de capital naționale a obligat atât emitenții cât și investitorii să considere tot mai mult rolul agențiilor independente de rating, acestea devenind treptat unicul instrument în a ajuta atât emitenții în promovarea propriilor emisiuni, cât și investitorii în efectuarea unor evaluări corecte ale oportunităților de investiții. Treptat, implicarea acestora pe piețele de capital și de credit a devenit suficient de mare încât să existe un consens în ceea ce privește rolul esențial al acestora în a promova o creștere continuă și stabilitate în piețele de capital, domestice sau internaționale. Datorită acestui lucru am dedicat un capitol separat instituțiilor de credit internaționale. Acesta debutează printr-o evaluare a rolului agențiilor de rating, cuprinzând o descriere a activității acestora, a tipurilor agențiilor (ele se deosebesc prin dimensiune, activitățile asupra cărora își concentrează analizele, și metodologiile adoptate) și a procesului de rating.

Atenția se mută apoi asupra activităților specifice ale agențiilor de rating. Prima sub-secțiune se concentrează asupra clienților acestora, identificați ca tipuri de utilizatori ai ratingurilor de credit (emitenții de titluri, investitorii în titluri privați, investitorii instituționali, investitorii în

acțiuni, intermediarii instituționali, autoritățile de reglementare, creditorii și reprezentanții altor segmente de afaceri).

Următorul sub-capitol se concentrează asupra barierelor existente la intrarea pe piață a noilor agenții. Între acestea, cea mai importantă este construirea unei reputații, întrucât emitenții vor căuta să obțină ratinguri doar de la acele agenții a căror reputație poate sprijini calificativele emise de acestea. Reputația în acest context se construiește pe baza acurateții ratingurilor și promptitudinii cu care comunicatele de presă sunt acordate.

În continuare au fost discutate aspectele ce țin de comunicarea publică a ratingurilor, metodologiile folosite și transparența acestora, conflictele de interes ce pot exista în activitatea agențiilor de rating; între acestea, taxele achitate de către emitenții de titluri și accesul la surse non-publice de informație ce pot fi folosite în alte activități decât cele de evaluare în perspectiva acordării de ratinguri. La acestea se adaugă apelarea la servicii de consultanță oferite de aceleași agenții de rating și menținerea de relații financiare între emitenți și agenții, cum ar fi deținerea de acțiuni în compania ce urmează să fie evaluată sau orice tip de afiliere cu aceasta.

Un capitol separat a fost dedicat criticilor aduse agențiilor de rating, dată fiind anvergura efectelor pe care evaluarea acestora o poate produce asupra clienților. Între acestea, relațiile prea strânse pe care acestea le dezvoltă de-a lungul timpului cu administrațiile companiilor ce sunt evaluate de agenții, lipsa de promptitudine în coborârea unui rating atunci când un risc anume este identificat cu privire la o companie, faptul că reducerea unui rating se poate afla la originea formării unui cerc vicios a cărui finalitate este degradarea accentuată a situației financiare a companiei evaluate, rolul de oligopol pe care aceste agențiile îl joacă pe piața de rating (cauzată de dificultatea de câștigare a reputației de către agențiile nou-înființate), erorile de evaluare dovedite în cazul produselor structurate (portofolii (*CDOs*) formate din credite cu calitate redusă au primit cele mai bune ratinguri) și contradicția existentă între rolul lor de cvasi-reglementare a piețelor și faptul că ele sunt organizate ca instituții orientate spre profit.

Următorul capitol este dedicat prezentării principalelor agenții de rating, Standard & Poor's, Moody's și Fitch, și tipurilor de rating pe care acestea le produc. Secțiunea dedicată riscurilor endogene se încheie cu un capitol ce tratează aspectele de reglementare principale ale activității de rating. Din aceasta perspectivă sunt prezentate principalele aspecte ale independenței agențiilor de rating și conflictele acestora de interes, publicarea ratingurilor, diseminarea publică a acestora, accesul preferențial la sursele de informație, accesul pe piață al noilor agenții, și modul în care instituțiile publice de reglementare controlează ratingurile nesolicitate, făcute preponderent de către noile agenții ca mijloc de câștigare a reputației.

Acest capitol încheie prima jumătate a tezei, dedicată evaluării riscurilor de tip endogen, din care am identificat pe cel de credit ca fiind cel mai important, din perspectiva companiei ce își propune să investească în străinătate. Discuția va continua cu evaluarea riscurilor de tip exogen, iar un model autoregresiv condițional heteroskedastic va fi propus.

C. Grupa riscurilor exogene. Perspective în modelarea și previzionarea volatilității utilizate în estimarea riscului

Prezenta teză își propune să ofere un îndrumător cu privire la evaluarea riscului cu care companiile se confruntă atunci când investesc în străinătate. Există mai multe posibilități prin care riscul noului mediu poate fi evaluat, dar, precum a fost menționat în partea introductivă, cea mai potrivită metodă este aceea de a estima viitorul companiilor ce își desfășoară activitatea în același sector cu cel în care compania în cauză dorește să investească. Spre exemplu, dacă compania A din Franța își propune să investească în sectorul IT din Statele Unite, cel mai probabil va încerca să-și evalueze riscul asociat acestei decizii prin evaluarea riscului cu care celelalte companii deja existente în sectorul IT american (spre exemplu al companiilor de la B la Z) se confruntă. Pentru a asigura rigurozitatea necesară unei astfel de analize, o metodă potrivită de a evalua riscul sectorului este aceea de a evalua riscul unui portofoliu format din acțiunile tuturor companiilor B-Z activând în respectivul sector. Dacă prin convenție asimilăm riscul unui portofoliu cu volatilitatea acestuia, problema estimării riscului devine una de previzionare a volatilității viitoare a unui portofoliu format din randamentele acțiunilor unor companii interdependente.

Există trei probleme legate de previzionarea volatilității unui astfel de portofoliu:

1. Un număr mare de acțiuni incluse în portofoliu poate face problema previzionării volatilității extrem de dificilă. În cazul unor sute sau mii de variabile incluse, numărul estimărilor de efectuat ar fi atât de mare încât problema ar deveni extrem de dificil de rezolvat.
2. Dată fiind lipsa unui consens existent între cercetători în privința superiorității unui model sau grup de modele de previzionare a volatilității, alegerea unui model anume rămâne o întreprindere extrem de subiectivă. În condițiile coexistenței în literatură a unui număr mare de modele, nominalizarea de către o companie a celei mai performante tehnici de evaluare a volatilității pune în dificultate realizarea unor activități de decizie sau de management al riscului.
3. Companiile incluse în portofoliu ar putea evolua într-o manieră integrată. Aceasta înseamnă că volatilitatea randamentelor acțiunilor ar putea avea un grad de corelație semnificativ. Astfel, informația inclusă în volatilitatea randamentelor unei anumite acțiuni s-ar putea regăsi, total sau parțial, în volatilitatea randamentelor unei alte acțiuni. Prin urmare, existența unor multiple corelări între șirurile de date ar putea duce la multiplicări acelorași informații în portofoliul de date analizat, problema estimării volatilității devenind imprecisă și dificil de rezolvat computațional.

Exercițiul empiric care urmează își propune să ofere o abordare critică a modelului Principal Components GARCH (PC-GARCH) și să ofere suport următoarei concluzii: modelul PC-GARCH este cel mai potrivit de utilizat în aplicațiile ce au ca scop evaluarea și previzionarea volatilității randamentelor portofoliilor foarte largi de acțiuni, conținând sute sau mii de variabile. Calitățile modelului PC-GARCH sunt

puse în valoare din perspectiva raportului calitate/cost oferit de acesta în raport cu orice model alternativ. Deși un studiu empiric va fi inclus pentru atât pentru a prezenta modul în care PC-GARCH funcționează cât și pentru a evidenția avantajele pe care această metodă le oferă, testul nu va fi folosit în scopul comparării directe a modelului PC-GARCH cu oricare altă metodă, pentru care ar trebui să fie testate sute sau mii de variabile pentru fiecare model considerat. Concluziile legate de PC-GARCH vor rezulta din procedura însăși, chiar dacă va fi realizată cu ajutorul a șapte seturi de variabile. Totuși, dat fiind faptul că pentru a-și demonstra superioritatea tehnicile de tip GARCH necesită seturi mari de date (cel puțin câteva sute de variabile cu cel puțin 5000 de observații fiecare), concluziile finale recomandă ca pentru o punere clară în evidență a avantajelor metodei PC-GARCH să se utilizeze sute sau mii de variabile, precum în acest caz serii de observații ale randamentelor acțiunilor selectate. Accesul limitat la surse largi de informație și logistica tehnologică limitată disponibilă pentru prezentul exercițiu au impus ca exemplul empiric ce urmează să se limiteze la un portofoliu format din doar șapte acțiuni de companii.

Precum s-a menționat anterior, superioritatea modelului PC-GARCH este pusă în evidență prin prisma raportului calitate/cost ce pune în balanță doi factori: primul, calitatea previziunilor obținute, înțelegând prin aceasta abilitatea modelului de a exprima relația dintre variabilele exogene și cele endogene, prin considerarea autocorelărilor și efectelor de interacțiune existente în cadrul datelor, și apoi, al doilea factor, cantitatea eforturilor computaționale necesare obținerii rezultatului și nivelului de calitate urmărit.

Articolele anterioare care au fost scrise pe acest topic au evaluat în exclusivitate beneficiile utilizării analizei componentelor principale în modelele ortogonale. Alexander (2000) a descris o astfel de analiză dar fără a identifica vreo metodologie care să asocieze teoria componentelor principale cu un model GARCH. Burns (2005) a oferit o astfel de metodologie, dar fără nici o implementare empirică. Totodată, niciunul dintre articole nu a discutat componenta de cost în utilizarea nici uneia dintre metodele menționate mai sus.

Prezentul studiu se adresează următoarelor două aspecte insuficient abordate anterior. Își propune o clasificare a modelelor de previzionare a volatilității luând în considerare și factorul de cost, punând în balanță cantitatea eforturilor computaționale necesare obținerii rezultatelor și calitatea previziunilor obținute, și aplică, în sprijinul soluției propuse, o metodă (a componentelor principale) la un model multivariat GARCH, fără a fi anterior testat de către vreun alt autor (a cărui metodologie a fost totuși descrisă succint de către Burns). Suplimentar, implementarea acestui model include elemente legate de testarea GARCH, nementionate anterior.

Unele modele necesită, dată fiind complexitatea acestora și dimensiunea portofoliului de date care se ia în considerație, să estimeze un număr mult prea mare de parametri. În acest caz, estimarea modelului poate lua mult prea mult timp, iar calitatea

rezultatelor nu echivalează uneori cu resursele de timp și logistică investite, atunci când acestea sunt considerabile. Uneori se poate dovedi util să se realizeze un tip de schimb între calitatea rezultatelor obținute și costuri (reprezentate de cantitatea timpului necesar obținerii respectivului nivel de calitate, și de alte tipuri de costuri computaționale existente (tehnologice, informaționale, etc.)). Cu alte cuvinte, se poate dovedi util să se obțină rezultate care din punct de vedere al acurateții să reprezinte de exemplu doar 80% din nivelul maxim ce se poate obține, dar timpul necesar obținerii acestor rezultate să fie redus la o treime.

Pentru primul tip de factori, acela care are în vedere calitatea rezultatelor, voi justifica superioritatea modelelor de tip GARCH în comparație cu cele elaborate anterior. Astfel, discuția din teză a pornit de la modelele ARMA și a fost fundamentată pe o abordare ce justifică motivul pentru care fiecare redefinire a fiecărui model (care de obicei încorporează o generalizare) reprezintă o îmbunătățire în comparație cu modelul anterior definit. Astfel a fost justificat de ce ARCH este mai bun decât ARMA și de ce GARCH este mai bun decât ARCH. Concluzia la această etapă este că, în condițiile manipulării cu seturi complexe de date, GARCH este cel mai bun model pentru a fi folosit în previzionarea volatilității. Discuția însă va continua cu modelul PC-GARCH și avantajele acestuia.

C.1 Ce reprezintă volatilitatea?

În contextul informal al discuțiilor zilnice obișnuite, volatilitatea este menționată drept o reprezentare a fluctuațiilor ce pot fi observate în evoluția unui proces sau fenomen, într-o perioadă anume de timp. În domeniul științelor economice, volatilitatea este folosită în special pentru a ilustra mișcarea factorilor aleatori (cu o mișcare impredictibilă, cel mult estimabilă), componenți ai seriilor de timp, fără obligativitatea ca reprezentarea lor să implice și măsurarea acestora. De fapt, științele economice reprezintă domeniul în care a luat naștere interesul pentru modelarea volatilității, în special în ceea ce privește seriile de timp.

În mod specific, în științele economice financiare, volatilitatea caracterizează deviația standard instantanee a componentei aleatoare de tip Wiener, într-un model de difuzie în timp continuu. Teoria de evaluare a acțiunilor folosește volatilitatea implicită care se definește astfel. Alte surse definesc volatilitatea mai simplu, drept deviația condițională standard a randamentului oferit. Alte teorii financiare se referă la volatilitate în sensul mai larg, comun teoriilor economice sau econometrice, spre deosebire de formulări mai restrânse, făcute spre a servi obiectivelor specifice ale studiilor ce le folosesc. Astfel, lingvistica volatilității diferă de-a lungul domeniilor, deși sensul ei de bază este menținut.

Previziunea volatilității în seriile financiare de timp ale randamentelor acțiunilor reprezintă domeniul cel mai larg pe care volatilitatea îl ocupă în teoriile economico-financiare. Specificul ei a fost evidențiat de Campbell, Lo și MacKinlay (1997) astfel:

„...ceea ce distinge economia financiară de celelalte domenii este rolul central pe care incertitudinea îl joacă atât în teoria financiară cât și în implementările ei empirice... Într-adevăr, în absența incertitudinii, problemele de economie financiară s-ar reduce la exerciții ale teoriei macroeconomice de bază” (p. 3).

Pe lângă incertitudine, care plasează fiecare discuție în spațiul probabilităților, ceea ce diferențiază și mai mult topicul volatilității în finanțe de cel al teoriei microeconomice este caracterul său neobservabil, latent și mișcarea sa stocastică în timp. De cele mai multe ori volatilitatea este neobservată, iar metrica sa poate fi evidențiată mai degrabă prin estimare decât prin măsurare directă. Mai mult, ceea ce complică și mai mult discuția, pe lângă existența unui nivel semnificativ de incertitudine în orice piață financiară, este caracterul latent al acestei incertitudini. Acesta face ca procesul de luare a deciziilor în domeniul financiar să fie mai complex și mai dificil de întreprins cu modele standard de optimizare, utilizate în mod tipic în alte domenii economice.

Modelele de volatilitate pot fi formulate în timp continuu sau discret, depinzând de scopul pentru care se fac previziunile, de tipul de date folosite și, desigur, de disponibilitatea acestora. Acuratețea modelelor crește odată cu gradul de corespondență a datelor cu realitatea. Și întrucât activitățile de tranzacționare și evaluare ce au loc în piețele financiare lichide de astăzi se desfășoară mai mult într-o manieră continuă decât într-una discretă, utilizarea de date în timp continuu ar îmbunătăți capacitățile predictive ale modelelor, și prin urmare previziunile acestora.

Totuși, utilizarea modelărilor în timp continuu ridică mari dificultăți în ceea ce privește estimarea, căreia i se adaugă probleme legate de colectare a datelor, pentru care observații continue rareori există. Astfel, cea mai bună abordare a evaluării prețurilor și a randamentelor financiare este aceea de a o gândi sub forma unui proces discret de observații ale unui fenomen ce se dezvoltă în timp continuu. Totuși, în unele contexte, va fi mai folositor să se definească direct un model formulat în timp discret. Nu există nici o contradicție formală între abordările discrete și cele continue, astfel încât este, în principiu, aproape întotdeauna posibil să se derive implicațiile distribuționale ale unei serii de preț observate doar discret, printr-un model formulat în timp continuu. Între timp, așa cum a fost menționat anterior, formularea și estimarea empirică a modelelor în timp continuu impune numeroase provocări.

Deși multe dintre modelele formulate în timp discret nu sunt formal consistente cu procesele ce descriu mișcarea în timp continuu a prețurilor, ele sunt mult mai simple de utilizat din perspectiva inferențială și prin urmare, rămân preferate în majoritatea exercițiilor empirice de previzionare.

C.2 Clasificarea modelelor de previziune a volatilității

Diverse tehnici dezvoltate pentru obținerea unor estimatori ai volatilității au fost elaborate în mod continuu în ultimele trei decenii. Ele pornesc de la modele extrem de simple care utilizează așa-numitele ipoteze „naive” (de tip aleatoriu („random walk”))

până la modele condițional heteroskedastice complexe ale grupului ARCH (până la GARCH și derivate ale acestuia).

Cele mai dezbătute modele de volatilitate de tip univariat sunt modelele autoregresive condițional heteroskedastice propuse de Engle (1982) și cele generale ARCH (GARCH) propuse de Bollerslev (1986). Numeroase extensii ale acestora au dobândit importanță ulterior precum 'exponential GARCH' (EGARCH) propus de Nelson (1991) sau 'conditional heteroskedastic autoregressive moving average' (CHARMA) elaborat de Tsay (1987). Alte modele utilizate pentru previzionarea volatilității au fost modelul 'random coefficient autoregressive' (RCA) al lui Nicholls și Quinn (1982) și modelele de volatilitate stocastică (SV) propuse de Melino și Turnbull (1990), Taylor (1994), Harvey, Ruiz și Shephard (1994) și Jacquier, Polson și Rossi (1994), etc.

Recenzii extinse ale literaturii scrise pe acest topic ce pot fi consultate pentru o mai largă înțelegere a modului în care modelarea volatilității a evoluat în timp au fost scrise de către Bollerslev, Chou și Kroner (1992), Bera și Higgins (1993), Bollerslev, Engle și Nelson (1994) și mai recent de către Andersen, Bollerslev, Christoffersen și Diebold (2005). În teză poate fi găsită o analiză completă a evoluției conceptului de previzionare a volatilității de-a lungul timpului, care va permite cititorului să înțeleagă care au fost cerințele cărora studiile mai recente au încercat să le răspundă și de ce modelele de previzionare mai recente sunt considerate a răspunde mai bine problemei previzionării volatilității.

În general, fiecare model are propriile avantaje și dezavantaje, astfel că având la dispoziție un număr așa de mare de modele, toate desemnate a servi aceluiași scop, este important de a distinge și identifica în mod corect fiecare model, cu caracteristicile fiecăruia, în scopul stabilirii celui care oferă cele mai bune predicții.

Totuși, un consens general în privința clasificării modelelor din punct de vedere al calității previziunilor făcute, nu a fost găsit. Acest lucru provine din faptul că literatura conține studii cu concluzii contradictorii în ceea ce privește calitatea previziunilor oferite de fiecare model. Subiectivismul se formează din numeroase surse, începând de la faptul că observațiile condiționale sunt neobservate și astfel nu există nici o modalitate naturală și intuitivă de a modela heteroskedasticitatea condițională, astfel că fiecare model va încerca să înglobeze elemente pe care autorul său le va considera importante și până la faptul că modele cu capacități de previzionare deficitare în toate aplicațiile nu au fost găsite.

Clasificarea depinde de o varietate de cauze ce pot fi legate fie de modul în care modelele înseși au fost definite, fie de metodologia de comparare folosită (metode 'in-sample' sau 'out-of-sample'), de subiectul analizei (volatilitatea ratelor de schimb sau volatilitatea randamentelor acțiunilor), de orizontul de previzionare sau de alegerea modului de calculare a erorilor. Spre exemplu, Brailsford și Faff (1996) au găsit că clasificarea performanțelor modelelor depinde de alegerea parametrilor de calculare a erorilor, pentru fiecare dintre aceștia fiind identificate diferite structuri de clasificare.

Poate cea mai potrivită caracterizare a literaturii este aceea a unui cadru compus dintr-un set eterogen de rezultate. Totuși, în ciuda complexității evidente și a lipsei de omogenitate, literatura **tinde** (subliniez acest cuvânt întrucât afirmația ce urmează provine dintr-o sinteză a literaturii scrise, însă în lipsa vreunui studiu științific integrat

care să o confirme final) să agreeze ideea că modelele de tip GARCH oferă în general previziuni superioare ale volatilității randamentelor acțiunilor (în ansamblul tuturor modelelor de previzionare a volatilității). Brailsford și Faff (1996) au fost printre cei care au ajuns la o astfel de concluzie. Folosind patru estimatori de eroare, ei au investigat abilitatea predictivă 'out-of-sample' a unsprezece modele (un model 'random walk', un model 'historical mean', un model 'moving average', un model 'exponential smoothing', un model 'exponentially weighted moving average', un model 'simple regression', două modele GJR (Glosten-Jagannathan-Runkle) GARCH (un model GJR-GARCH(1,1), un model GJR-GARCH(3,1)) și două modele GARCH (un GARCH(1,1) și un GARCH(3,1)), testate cu date lunare australiene. Concluzia lor a fost aceea că modelele de tip ARCH și regresia simplă oferă previziuni superioare, cu o singură rezervă, aceea că alegerea modelelor de previzionare depinde de alegerea formulei de calculare a erorilor statistice. Akgiray (1989) a ajuns de asemenea la concluzia superiorității modelului GARCH(1,1) (în comparație cu modelele tradiționale, mai simple) testat cu date americane. Pe cealaltă parte, Dimson și Marsh (1990) au obținut rezultate ce se află în favoarea modelelor mai simple. Totuși, toate studiile converg într-o privință anume, și anume aceea că modelul EWMA ('exponential weighted moving average') s-a clasificat în fiecare aplicație între cele mai bune modele de previzionare.

Așa cum a fost menționat, literatura scrisă pe acest topic conține concluzii contradictorii cu privire la calitatea previziunilor diferitelor modele. Mesajul principal este acela că previzionarea volatilității rămâne o întreprindere extrem de complicată. Există studii care subliniază superioritatea modelelor mai complexe, precum cele din categoria ARCH (precum a fost exemplificat în paragraful anterior), în timp ce există studii care, dimpotrivă, susțin superioritatea modelelor mai simple. Această situație este văzută drept una extrem de problematică, din cauza dificultății pe care contradicția existentă o determină în alegerea celui mai potrivit model în previzionarea volatilității în activitățile de analiză și cele de decizie.

Celei de-a doua categorii de studii, și anume cea care susține ideea superiorității modelelor mai simple, îi aparține studiul condus de Dimson și Marsh (1990). Conform acestuia, modelele de bază oferă o acuratețe sporită a previziunilor, cu mențiunea că modelele de tip ARCH nu au fost incluse în studiu. Mai exact, modelul 'exponential smoothing' și cel de regresie au fost identificate ca fiind superioare, însoțind concluzia cu un semnal de alarmă îndreptat către literatură conform căruia cele mai bune modele de previzionare pot să nu fie cele mai complexe și mai recente modele. O concluzie similară a fost avansată de Tse (1991) și Tse și Tung (1992) care, testând cu date japoneze și singaporeze, au găsit că modelul 'exponentially weighted moving average' (EWMA) a oferit previziuni mai bune decât modelele ARCH, punând totodată sub semnul întrebării superioritatea modelelor ARCH.

Aceluiași grup de studii îi aparține lucrarea lui Hansen și Lunde (2001) care au utilizat valori estimate la intervale mai mici de o zi (intraday) pentru compararea modelelor de volatilitate. Concluziile acestuia au indicat faptul că modelele mai avansate nu oferă previziuni îmbunătățite față de modelul GARCH(1,1).

Deși a fost evidențiat efectul de 'clustering' (concentrare a volatilității pe perioade mici de timp) al volatilității randamentelor acțiunilor, se pare că doar de când modelul GARCH a fost enunțat de către Bollerslev (1986), dependențele temporale au putut fi formal modelate folosind modele econometrice. Aceasta a sprijinit succesul empiric al modelelor de tip GARCH, numeroase articole remarcând succesul în modelarea 'in-sample' a volatilității randamentelor. Curând după, câteva articole (Andersen și Bollerslev 1998, Andersen et al. 1999) s-au adresat caracterului latent (sau neobservabil) al volatilității ce evoluează stocastic în timp. Volatilitatea acțiunilor constă în volatilități 'intraday' și fluctuații între zile. Spre deosebire de preț, care este o variabilă ce poate fi măsurată instantaneu, volatilitatea este o variabilă de stoc și prin urmare trebuie măsurată pe o anumită perioadă. Aceasta a fost în mod constant o problemă pentru econometricieni deoarece volatilitatea nu este observabilă și măsurabilă în mod exact, ci mai degrabă estimată. Neobservabilitatea acesteia face ca evaluarea performanțelor de previzionare a modelelor condițional heteroskedastice să fie dificilă. Caracterul latent al volatilității transformă estimarea volatilității și problema previzionării într-o problemă de 'filtrare' în care „adevărate” volatilitate nu poate fi determinată exact, ci doar extrasă cu un anumit grad de eroare. Acest lucru ar putea ridica probleme întrucât volatilitatea estimată de către modele trebuie să fie comparată cu volatilitatea „reală”, implicită. Erorile pot fi atunci un efect al modelului care realizează previziunile sau un efect al modului în care 'adevărate' volatilitate este estimată. Articolele menționate anterior în acest paragraf au adus noi puncte de vedere către înțelegerea posibilelor surse ale coexistenței unui număr atât de mare de concluzii contradictorii legate de clasificarea performanțelor modelelor. Acestea menționează că eșecul clasei de modele de tip GARCH în a obține previziuni superioare ale volatilității nu reprezintă un eșec în sine al modelului GARCH, ci mai degrabă un eșec de estimare corectă a volatilității „reale” cu care previziunea este comparată și pe baza căreia se calculează estimatorii de eroare ai modelului. Aceste studii susțin faptul că folosirea randamentelor zilnice ale acțiunilor drept valori „reale” ale volatilității zilnice, este o greșală întrucât o astfel de valoare „reală” ar conține o componentă de eroare (cu media zero și varianță constantă) mare și cu foarte mult „zgomot”, independent de volatilitatea implicită. Andersen și Bollerslev sugerează folosirea valorilor „intraday” ca alternativă a exprimării volatilității „reale”, „adevărate”. O astfel de măsură, numită „volatilitate integrată” oferă posibilitatea unei estimări a volatilității mult mai precisă și mai consistentă. Aceasta reprezintă un pas înainte în problema previzionării volatilității, întrucât indică necesitatea utilizării de date cu înaltă frecvență (tip 'tick by tick') în estimările empirice.

În ceea ce privește subiectul testelor, există o mare prevalență pentru piețele internaționale ale cursului de schimb și pentru piețele naționale de valori mobiliare. Autori care au testat volatilități cu privire la ratele de schimb sunt Taylor (1987), Lee (1991), West și Cho (1995), Andersen și Bollerslev (1998), Brooks și Burke (1998), Andersen, Bollerslev și Lange (1999), McKenzie (1999), Andersen, Bollerslev, Diebold și Labys (2002), Klaasen (2002), Vilasuso (2002) și Balaban (2004). O notă diferită este dată de West și Cho (1995) care nu au putut arăta superioritatea nici unui dintre modelele testate.

Teste empirice au fost făcute folosind atât metode 'in-sample' cât și 'out-of-sample'. Testele, în general, sunt făcute cu date ale cotațiilor acțiunilor într-o anumită țară: Australia (Brailsford și Faff, 1996, Walsh și Tsou, 1998), Japonia (Tse, 1991), Germania (Bluhm și Yu, 2000), Noua Zeelandă (Yu, 2002), Suedia (Frennberg și Hannsson, 1996), Elveția (Adjaoute, Bruand și Gibson-Asner, 1998), Turcia (Balaban, 2000), Marea Britanie (Dimson și Marsh, 1990, Loudon, Watt și Yadav, 2000 și McMillan, Speight și Gwilym, 2000), Statele Unite (Akgriray, 1989, Pagan și Schwert, 1990, Hamilton și Lin, 1996, Brooks, 1998). O abordare aparte este oferită de Franses și Ghijsels (1999) care au realizat un studiu cu date din patru țări (Olanda, Germania, Spania și Italia). Comun tuturor acestor studii este numărul relativ mic de modele luate în considerare.

O analiză mai completă a fost întreprinsă de Balaban, Bayar și Faff (2004) care au luat în considerare un număr extins de metode de previzionare ce au fost testate cu date provenind atât din cadrul țărilor cu economii emergente cât și din cadrul țărilor dezvoltate. Procedura utilizată a fost cea propusă inițial de Brailsford și Faff (1996), însă spectrul de date a fost extins de la o singură țară (Australia) la cincisprezece țări (Belgia, Canada, Danemarca, Finlanda, Germania, Hong Kong, Italia, Japonia, Malaiezia, Olanda, Filipine, Singapore, Tailanda, Marea Britanie și Statele Unite). Au fost testate unsprezece modele, aceleași cu cele propuse de Brailsford și Faff (1996), folosind totodată aceleași formule de calcul a erorilor (simetrice și asimetrice). Ei au concluzionat că, în condițiile utilizării funcțiilor de eroare convenționale, simetrice, modelul 'exponential smoothing' oferă previziunile cele mai bune. În același context, al măsurătorilor simetrice, modelele de tip ARCH au fost găsite drept inferioare din punct de vedere al calității estimatorilor. Atunci când însă s-au folosit parametri asimetrice de măsurare a erorilor, în cazul în care predicțiile negative (cele care s-au dovedit a fi sub nivelul volatilității reale) au fost penalizate mai mult, grupul ARCH de modele a oferit cele mai bune previziuni. Însă când predicțiile pozitive (cele dovedite a fi peste nivelul volatilității reale) au fost penalizate mai mult, modelul 'exponențial smoothing' s-a dovedit din nou mai bun, iar modelele de tip ARCH, inferioare.

Studii desfășurate pe eșantioane unitare, ce cuprind o singură țară, au luat de asemenea în considerare performanțele modelelor derivate din GARCH. Deși datele utilizate în aplicații au un spectru mai degrabă restrâns, concluziile acestora sunt de menționat în legătură cu mai recente reformulări ale modelelor GARCH. Astfel, Marcucci (2005) a demonstrat faptul că modelele de tip 'Markov regime switching GARCH' sunt superioare tuturor modelelor standard de tip GARCH în previzionarea volatilității pentru orizonturi scurte de timp, în timp ce pentru orizonturi mai largi, modelele simetrice standard GARCH se dovedesc mai bune.

Barucci și Renó (2001) au găsit faptul că utilizând serii de timp simulate (bazate pe integrarea seriilor de timp care ar permite exploatarea structurii temporale a datelor cu frecvență înaltă prin includerea tuturor observațiilor în estimarea volatilității) performanța modelului GARCH ar fi sporită.

Voi încheia secțiunea trecerii în revistă a literaturii scrise pe acest topic prin prezentarea a două studii ce scot în evidență eterogeneitatea existentă în clasificarea

modelelor de volatilitate. Primul este un studiu întreprins de Poon și Granger (2003) care au comparat 93 (din care au extras în final 66 ce au fost considerate relevante pentru respectivul studiu) de articole care s-au concentrat pe clasificarea modelelor de previzionare a volatilității. Ei au grupat modelele în patru categorii astfel:

-HISVOL care cuantifică următoarele modele: 'historical volatility models' ce cuprind 'random walk', 'historical averages of squared or absolute returns', 'time series models' ce se fundamentează pe volatilitatea istorică folosind 'moving averages', 'exponential weights', 'autoregressive models', 'fractionally integrated autoregressive absolute returns models'.

-Grupul GARCH care cuprinde toate derivațiile modelelor ARCH, GARCH, etc.

-ISD care reprezintă modelele ce se referă la deviația standard implicită a opțiunilor, bazate pe modelul Black Scholes și derivațiile acestuia.

-SV care reprezintă modelele stocastice de volatilitate.

Rezultatul acestui studiu arată astfel:

	Numărul de studii	Procentaj
HISVOL > GARCH	22	56%
GARCH > HISVOL	17	44%
HISVOL > ISD	8	24%
ISD > HISVOL	26	76%
GARCH > ISD	1	6%
ISD > GARCH	17	94%
SV > HISVOL	3	
SV > GARCH	3	
GARCH > SV	1	
ISD > SV	1	

Sursa: Poon și Granger (2003)

Al doilea studiu reprezintă propriul meu sumar al celor mai recente 50 de articole scrise pe acest topic până la momentul iulie 2009, cu scopul completării sintezei literaturii. Tabelul cu concluziile fiecărui studiu poate fi consultat în textul integral al lucrării de doctorat.

Astfel, întreaga diversitate în clasificări indică faptul că cercetarea modelelor de previzionare a volatilității este încă departe de explorarea deplină și faptul că previzionarea volatilității este încă o întreprindere dificilă dar totuși mereu actuală.

C.3 Evaluarea calității modelelor de previzionare a volatilității

O discuție cu privire la instrumentele și metodologia de măsurare a calității este necesară la acest punct. Ce face un model mai bun decât altul? Cum se definește calitatea și cum se măsoară?

Între cercetările care au evidențiat superioritatea modelelor mai complexe există studiul realizat de Brailsford și Faff (1995) care, utilizând date empirice, a arătat că modelele mai avansate din clasa ARCH și un simplu model de regresie s-au dovedit superioare. O a doua concluzie a fost aceea că diferitele clasificări ale modelelor depind de alegerea formulei de calcul a erorilor în determinarea acurateții previziunilor. Majoritatea literaturii exprimă calitatea drept o măsură absolută sau reală a parametrilor de eroare. Metodologia care oferă cea mai completă bază de argumentare și asupra căreia argumentația acestei lucrări se va construi, este aceea a lui Brailsford și Faff (1995). M-am oprit asupra acestei metodologii datorită următoarelor argumente: folosește mai multe (patru) criterii de clasificare (în funcție de tipul de eroare ales), folosește teoria cuprinsă în studiile anterioare (Akgiray (1989), Dimson și Marsh (1990), Tse (1991) și Tse și Tung (1992)) și astfel însumează și investighează toate modelele discutate anterior și nu în ultimul rând este o metodă relativ simplă datorită cărui fapt lasă puțin spațiu erorilor. Voi descrie pe scurt această metodă, întrucât pe baza acestei metodologii, voi continua argumentația în favoarea modelului PC-GARCH.

În articolul lui Brailsford și Faff, calitatea unui model a fost pusă în evidență prin calcularea a patru parametri de eroare, aplicați la fiecare din cele unsprezece modele utilizate pentru previzionarea volatilității lunare:

1. Eroarea medie ('mean error') definită prin expresia $ME = \frac{1}{90} \sum_{t=1}^{90} (\hat{\sigma}_t^2 - \sigma_t^2)$
2. Media erorilor absolute ('mean absolute error') definită de expresia $MAE = \frac{1}{90} \sum_{t=1}^{90} |\hat{\sigma}_t^2 - \sigma_t^2|$
3. Rădăcina pătrată a mediei diferențelor pătratelor ('root mean squared error') definită ca $RMSE = \sqrt{\frac{1}{90} \sum_{t=1}^{90} (\hat{\sigma}_t^2 - \sigma_t^2)^2}$
4. Media erorilor procentuale absolute ('mean absolute percentage error') exprimată sub forma $MAPE = \frac{1}{90} \sum_{t=1}^{90} |(\hat{\sigma}_t^2 - \sigma_t^2) / \sigma_t^2|$

unde $\hat{\sigma}_t^2$ reprezintă seria volatilităților lunare calculate, pe când σ_t^2 reprezintă seria volatilităților reale, observate.

Brailsford și Faff (1995) au ales să exprime fiecare (din cele patru mentionate) parametru de eroare în formă relativă, în care elementul cu care se compară fiecare eroare va fi eroarea ce va da cel mai slab model. Metodologia de comparare aleasă este cea 'out-of-sample', ceea ce înseamnă că autorii au ales un eșantion de 90 de observații (corespunzătoare a 90 de luni) asupra cărora au încercat să facă predicții cu

cele unsprezece modele selectate. Astfel că, pentru fiecare model folosit, ei au calculat erorile din diferența dintre realitate și previziuni, conform celor patru formule de calculare a acestora. Pentru fiecare model au obținut patru erori diferite. Fiecare model a fost apoi clasificat după mărimea erorilor date, realizate din compararea predicțiilor cu valorile reale. De asemenea s-au calculat erori relative, calculate sub forma unui raport format din erorile absolute ale fiecărui model cu erorile absolute de cel mai slab model (cel cu cea mai mare eroare absolută obținută anterior), pentru fiecare tip de eroare calculată. Factorul ce indică calitatea modelului este dat de diferența dintre erorile relative și cele absolute. Pentru fiecare eroare, modelul cu cea mai mare diferență era considerat modelul de bază (fiind modelul cu cea mai slabă performanță), în timp ce modelul cu cea mai mică diferență era desemnat drept modelul cu cea mai bună performanță. Notabil de menționat este faptul că pentru fiecare eroare (și model), avem (potențial) un alt model de bază (altfel spus un cel mai slab performer). De asemenea, puterea fiecărui test a fost calculată conform următoarei formule:

$$\frac{(\varepsilon_i - \hat{\varepsilon}_i) - (\varepsilon_b - \hat{\varepsilon}_b)}{(\varepsilon_b - \hat{\varepsilon}_b)}$$

în care ε_i reprezintă parametrul absolut de eroare al celui mai bun model, $\hat{\varepsilon}_i$ parametrul de eroare relativ al celui mai bun model, ε_b parametrul absolut de eroare al modelului de comparație, iar $\hat{\varepsilon}_b$ parametrul relativ de eroare al modelului de comparație.

Același rezultat (putere a testului) se poate obține prin deducerea fiecărui parametru de eroare relativ din cifra 1.

Pentru fiecare din aceste patru formule de calcul al erorilor s-au obținut răspunsuri diferite legate de care performanțele fiecărui model. Astfel, fiecărei erori i se poate asocia o altă interpretare și/sau diferite puteri în desemnarea celui mai bun/slab model.

Concluziile acestui studiu relevă faptul că clasificarea fiecărui model depinde de alegerea formulei de calcul al erorilor, dar se pare că modelul GARCH se clasifică pe cele mai bune poziții la oricare dintre formule. Această variabilitate în alcătuirea clasificărilor arată încă o dată hazardul potențial existent în selectarea celui mai bun model, pe baza alegerii arbitrare a formulei de calcul al erorilor.

Așa cum s-a menționat, voi lua în considerare acest model în privința clasificării intermediare (luând în considerare doar factorul calitate) a modelelor de previzionare a volatilității, datorită metodologiei clare și simple adoptate, ce cuprinde totodată toate abordările realizate anterior de către ceilalți autori. Astfel, voi clasifica modelele conform acestei metodologii și conform acesteia voi asuma superioritatea modelelor mai complexe (din clasa GARCH) în dauna celor mai simple. Pornind de la această ipoteză, se va construi în continuare o argumentație care își va propune să justifice superioritatea modelului PC-GARCH sub aspectul raportului calitate/cost în

aplicațiile ce presupun portofolii compuse dintr-un număr mare (de ordinul sutelor sau miilor) de variabile.

C.4 De ce modelul PC-GARCH?

Modelul GARCH împarte previziunile legate de varianță în două componente – autocorelații, sau volatilitatea în trecut, și inovații, sau șocurile exogene din volatilitatea variabilelor (randamentele acțiunilor). Folosirea unui model GARCH(1,1) ne conduce imediat la întrebarea: cât din inovație este cu adevărat „exogenă” și cât este explicată de „alți factori” ce nu au fost considerați în model? Pentru îmbunătățirea modelului, am putea începe prin considerarea altor variabile care ar putea influența volatilitatea estimatorului nostru (cu alte cuvinte să se endogenizeze o parte din exogeneitate). Dar adăugarea de noi variabile ne conduce la următorul dezavantaj al modelului GARCH: problema estimării parametrilor ar deveni mult prea complicată. Din cauza corelațiilor (de obicei diferite de zero) existente între variabilele folosite în modelul GARCH, problema ar necesita cantități semnificative de date și de putere computațională pentru obținerea unui estimator rezonabil de robust. De aceea urmărim să îmbunătățim previziunile volatilității unei variabile în comparație cu cele obținute prin GARCH, utilizând o nouă metodă care poate lucra cu variabile independente multiple. Acest lucru este realizat de către PC-GARCH.

În ceea ce urmează vor fi discutate aspecte ale estimărilor cu GARCH multivariat, neacoperite în secțiunile anterioare. Cunoaștem faptul că numărul parametrilor într-un model GARCH multivariat crește la o rată egală cu pătratul numărului variabilelor.

De exemplu, utilizarea a n variabile independente va face necesară estimarea a $\frac{n(n+1)}{2}$ parametri; acest lucru se datorează faptului că fiecare variabilă adițională aduce cu ea termeni de corelație cu alte variabile, și fiecare dintre acești termeni de corelație are propriul său parametru. Dimensionalitatea problemei și prin urmare necesarul de putere computațională sunt mai degrabă semnificative. Mai mult, estimarea unor parametri robusți impune utilizarea unor cantități semnificative de date. Separat de problemele de estimare, există probleme practice ce țin de stabilitatea predicțiilor: un număr mare de parametri utilizați drept inputuri în model ar rezulta frecvent în estimatori instabili. Din cauza naturii inerente a fiecărei proceduri statistice, ar putea fi zgomot în perioadele de estimare capturate ca semnale în modelul nostru.

Una dintre metodele propuse să facă problema mai tractabilă este PC-GARCH (un alt algoritm care folosește Teoria Componentelor Principale dar care este diferit în implementare este denumit Orthogonal GARCH). În acest studiu, un model simplu va fi utilizat pentru a ilustra performanțele acestei metode, în particular performanțele Analizei Componentelor Principale (PCA) folosită în combinație cu modelul GARCH, spre rezolvarea problemei mai sus definite.

Cum s-a menționat anterior, dimensionalitatea crescută a modelului multivariat GARCH se datorează unui număr larg de covarianțe existente între variabilele independente care intră în spațiul de parametri. Prin urmare, făcând aceste covarianțe

zero vom reduce dimensiunea problemei la n (sau altfel spus va trebui sa estimăm doar n parametri pentru fiecare model ARCH sau GARCH testat). Astfel, PCA este instrumentul ce va fi folosit pentru a simplifica problema si a o face tractabilă. PCA este o metodă de transformare a variabilelor independente originale în factori ortogonali. Folosind n variabile (posibil corelate) și aplicând PCA, se va reduce numărul de parametri de estimat la $2n + 1$, în loc de $\frac{n(n+1)}{2}$ (o creștere liniară în loc de una quadratică în numărul parametrilor de estimat). Astfel, metoda PCA ne va ajuta să reducem problemarea modelării unui GARCH multivariat la modelarea a n modele GARCH univariate. Metodologia pentru analiza ce va urma aparține lui Burns (2005). Există și alte metode alternative dezvoltate în literatură care folosesc PCA în combinație cu GARCH; exemple sunt Alexander (2000) și van der Weide (2002).

Definind pe scurt problema în termeni matematici, avem variabila y care este dependentă de k variabile independente. Fiecare variabilă independentă k va avea n observații istorice ce vor fi aranjate într-o matrice $\mathbf{X}$ de dimensiuni $n \times k$, și n observații istorice ale fiecărei variabile dependente, aranjate într-o matrice $\mathbf{Y}$ de ordinul $k \times 1$. În termeni foarte generali, vrem sa găsim o funcție f care să exprime legătura dintre variabilele independente și cele dependente: $\mathbf{Y} = f(\mathbf{X})$. Rezumând, problema cu găsirea acestei funcții este dată de următoarele:

- 1) Chiar și o creștere mică în k face problema intensivă din punct de vedere computațional și din punct de vedere al volumului de date necesar, și
- 2) O parte din variabilele independente sunt corelate: ele conțin informație comună, iar noi dorim să comasăm toată această informație comună într-o singură variabilă care să o reprezinte, obținând totodată variabile explanatorii independente, necorelate.

C.5 Analiza Componentelor Principale: O scurtă introducere a metodei

Analiza Componentelor Principale este un algoritm folosit în Analiza Factorială. Analiza Factorială este un nume generic dat unei clase de metode statistice multivariate care are ca scop principal identificarea structurii unei matrici de date. În mod specific, Analiza Factorială are două utilizări primare: sintetizarea informației și reducerea cantității de date cu care se lucrează. Sintetizarea rezultă din descrierea datelor cu un număr mult mai mic de variabile, în timp ce reducerea cantității de date se face ca urmare a transformării matricii de date într-o nouă matrice în care fiecare coloană corespunde unui factor³.

Analiza Componentelor Principale este o metodă folosită pentru extragerea surselor independente de informație dintr-o bază de date. Dintr-un set de k randamente staționare ale acțiunilor, vom obține k variabile ortogonale (independente) staționare, denumite componente principale. PCA este o tehnică clasică menită sa obțină variabile necorelate. Rezultatul obținut în urma aplicării PCA conține de asemenea

³ Dimensiune structurală comună

procentul cu privire la cât din variația totală cuprinsă în datele inițiale este explicată de fiecare componentă principală.

Dată fiind sensibilitatea rezultatelor și a procesului de sintetizare a datelor, înainte de a debuta în aplicarea metodei, se aplică o procedură standard de normalizare a variabilelor. Astfel, presupunem că fiecare coloană în matricea staționară are media zero și varianță unu, după ce în prealabil am scăzut din ea media eșantionului și am împărțit-o la deviația standard a aceleiași eșantion.

Fie matricea $\mathbf{X}$ cu coloanele $(x_1 \ x_2 \ \dots \ x_k)$ în care fiecare vector $\{x_i, 1 \leq i \leq k\}$ există astfel încât $\mathbf{X}'\mathbf{X}$ este o matrice simetrică de ordinul $k \times k$ cu 1 pe diagonală. $\mathbf{\Omega} = \mathbf{X}'\mathbf{X}$ este matricea de varianță-covarianță a variabilelor din $\mathbf{X}$, și de aceea este pozitiv definită. Pentru simplificare, vom considera $\mathbf{X}$ ca având doar o linie. Fiecare componentă principală va fi atunci o combinație a acestor coloane.

$$p_m = a_{1,m}x_1 + a_{2,m}x_2 + \dots + a_{k,m}x_k \quad 1 \leq m \leq k \quad (1)$$

În formă matriceală, (1) poate fi scrisă ca $\mathbf{P}_{1,m} = \mathbf{X}_{1,k}\mathbf{A}_{k,m}$ în care $\mathbf{A} =$

$$\begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \dots & \dots & \dots & \dots \\ a_{k1} & a_{k2} & \dots & a_{km} \end{pmatrix}.$$

$\mathbf{A}$ se numește matricea vectorilor eigen ai lui $\mathbf{\Omega}^4$. Ponderile $a_{i,m}$ asociate fiecărui x_i sunt alese dintr-un set de vectori eigen ai matricei de corelație $\mathbf{\Omega}$, astfel încât:

1. Componentele principale (PC) sunt ortogonale. Astfel, vom impune condiția ortogonalității matricei $\mathbf{P}$ asupra componentelor principale (întrucât aceasta este principala proprietate a acestor componente - ortogonalitatea) și, conform acesteia, vom căuta să găsim o matrice $\mathbf{A}$ ale cărei elemente vor fi ponderile care îndeplinesc această condiție. Cu alte cuvinte, vrem să știm care sunt acele $a_{i,m}$ astfel încât matricea lor, multiplicată cu o matrice $\mathbf{X}$ de observații, să ne dea o matrice ortogonală.
2. Prima componentă principală va explica cantitatea maximă din variația totală din $\mathbf{X}$, a doua componentă principală va explica cantitatea maximă din restul de variație, etc.

Știm din algebra matriceală că dacă alegem matricea $\mathbf{A}$ compusă din unități de vectori eigen, ortogonale în $\mathbf{X}\mathbf{X}'$, atunci componentele principale rezultante vor fi ortogonale.

⁴ Un vector de tip eigen este un vector a cărui dimensiune este dată printr-o transformare liniară. Este ca o săgeată a cărei direcție însă nu poate fi modificată. Indiferent dacă își reduce sau mărește dimensiunea conform transformării spațiului din care face parte, direcția sa nu se modifică. O valoare de tip eigen este factorul scalar atribuit vectorului eigen. Semnificația unei valori eigen are sens doar în contextul existenței unui vector eigen, de exemplu o săgeată a cărei dimensiune poate fi schimbată.

Înseamnă atunci că unica condiție pentru ca $\mathbf{P}$ să fie ortogonal este ca columnele matricei $\mathbf{A}$ să fie ortogonale.

În continuare ordonăm columnele lui $\mathbf{A}$ în ordine descendentă astfel: $a_{1,m}, a_{2,m}, \dots, a_{k,m}$ unde $m = \{1, 2, \dots, k\}$ (valorile eigen corespunzătoare). În acest fel, dacă $\mathbf{A}(a_{i,j})$, $i, j = \{1, \dots, k\}$ atunci a m -a coloană a matricei $\mathbf{A}$, notată ca $a_m = (a_{1,m}, a_{2,m}, \dots, a_{k,m})'$ va fi al $k \times 1$ - lea vector eigen corespunzător valorii eigen λ_m , iar coloanele vor trebui aranjate în așa fel încât $\lambda_1 > \lambda_2 > \dots > \lambda_k > 0$.

Vom defini o nouă matrice $\mathbf{\Lambda} = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_k \end{pmatrix}$ care va fi matricea diagonală a valorilor

eigen ale lui $\mathbf{\Omega}$, și observăm că

$\mathbf{X}'\mathbf{X}\mathbf{A} = \mathbf{A}\mathbf{\Lambda}$, de unde rezultă că $\mathbf{\Lambda} = \mathbf{A}'\mathbf{X}'\mathbf{X}\mathbf{A} = \mathbf{A}'\mathbf{\Omega}\mathbf{A}$. De asemenea, vom avea $(\mathbf{X}\mathbf{A})'\mathbf{X}\mathbf{A} = \mathbf{A}'\mathbf{X}'\mathbf{X}\mathbf{A} = \mathbf{\Lambda}$. Relația de mai sus va deveni atunci

$$\mathbf{\Lambda} = \mathbf{P}'\mathbf{P} = \mathbf{A}'\mathbf{X}'\mathbf{X}\mathbf{A} = \mathbf{A}'\mathbf{\Omega}\mathbf{A} \quad (2)$$

Deoarece $\mathbf{\Lambda}$ este o matrice diagonală, și pentru că este matricea de varianță-covarianță a matricei $\mathbf{P}$, atunci componentele (coloanele) lui $\mathbf{P}$ sunt necorelate. Deoarece $\mathbf{A}$ este ortogonal,

$\mathbf{A}' = \mathbf{A}^{-1}$ și $\mathbf{P}'\mathbf{P} = \mathbf{\Lambda}$. $\mathbf{A}' = \mathbf{A}^{-1}$ este echivalentă cu $\mathbf{X} = \mathbf{P}\mathbf{A}'$ care este $X_i = w_{i1}P_1 + w_{i2}P_2 + \dots + w_{ik}P_k$ unde X_i și P_i denotă coloanele matricelor $\mathbf{X}$ și respectiv $\mathbf{P}$. Astfel fiecare vector de date va fi o combinație liniară a principalelor componente. Proporția de variație totală din $\mathbf{X}$ care este explicată de a m -a componentă principală este $\lambda_m / (\text{suma valorilor eigen})$.

Astfel, operațiunea de scalare a variabilelor originale într-o matrice $\mathbf{A}$ de vectori unitari eigen conduce la obținerea componentelor (PC) necorelate ce pot fi folosite apoi pentru reducerea problemei inițiale multivariate GARCH într-un set de probleme univariate GARCH.

C.6 Metodologie

Așa cum a fost menționat la începutul discuției, rezultatele articolului aparținând lui Brailsford și Faff (1995) vor fi folosite în construirea argumentației celei de-a doua jumătăți a acestei teze și astfel, superioritatea modelelor de tip GARCH va fi asumată. Dar GARCH se poate dovedi uneori prea costisitor pentru a fi folosit, așa cum s-a menționat. Pentru aceasta, și la acest punct mă voi adresa celui de-al doilea factor care susține principala concluzie a celei de-a doua părți a tezei, utilizarea Analizei Componentelor Principale (PCA) se poate dovedi o soluție eficientă și la îndemână. PCA realizează două lucruri care îmbunătățesc modelul GARCH: reduce dimensionalitatea problemei și exclude autocorelările din date. Singurul aspect subiectiv al problemei rămâne legat de decizia punctului de separație. Altfel spus câtă calitate (exprimată prin acuratețea previziunilor) va fi sacrificată în favoarea cărui

volum de costuri salvat (cel mai des, în favoarea cărei economii de timp). Această abilitate de a stabili (unilateral de către utilizatorul modelului) raportul dintre calitatea rezultatelor și cost (timp) oferă modelului PC-GARCH flexibilitate, permițând elaborarea de strategii de previzionare a volatilității specifice fiecărei activități sau companii.

Anterior au fost prezentate principalele modele de previzionare de tip ARCH arătând ce a adus fiecare model în plus față de precedentul; apoi a urmat o prezentare a modelului PC-GARCH. Aceasta a debutat cu o discuție a Analizei Componentelor Principale și a modului în care PC-GARCH a fost construit. După prezentarea teoretică a modelului PC-GARCH, va urma o aplicație empirică. Atât partea teoretică cât și cea empirică vor fi împreună discutate cu scopul de a oferi o înțelegere completă a modului în care PC-GARCH funcționează. Ele vor contribui la principala concluzie a acestui capitol și anume aceea că PC-GARCH este superior tuturor modelelor alternative în aplicațiile cu portofolii largi de date.

C.7 Studiul experimental

C.7.1 Sinteza datelor

Scopul nostru este acela de a estima volatilitatea câștigurilor realizate din fluctuația prețului unui anumit portofoliu format din acțiuni intercorelate (Adobe, Apple, Autodesk, Cisco, Dell, Microsoft și 3M) folosind PCA combinat cu un model GARCH. Selecția acestor șapte acțiuni este motivată de faptul că PCA lucrează cel mai bine atunci când există o cantitate rezonabilă de corelații între variabile; există astfel o motivație întemeiată de a suspecta faptul că cele șapte acțiuni americane ar fi corelate.

Suntem astfel în poziția de a argumenta că volatilitatea acțiunilor Microsoft, de exemplu, nu este influențată numai de propria volatilitate trecută, dar și de volatilitatea trecută a celorlalte acțiuni incluse în portofoliu. Ca un exemplu ipotetic, o cantitate considerabilă din volatilitatea randamentelor acțiunilor Microsoft ar putea semnală un grad de instabilitate latentă în sectorul tehnologic; Adobe ziua următoare, cel mai probabil, va lua în considerare instabilitatea din sectorul tehnologic indusă de Microsoft și o va extrapola în previziunile activității sale. Deși studiul se limitează la doar aceste șapte șiruri de date, nu este sugerat faptul că acestea sunt singurele acțiuni care contează – acest studiu este doar o modalitate de a demonstra avantajele unei tehnici și de a argumenta de ce aceasta este optimă în previzionarea volatilității seriilor de timp intercorelate.

C.7.2 Eșantionul de date

Au fost selectate șapte șiruri de date, reprezentând randamente ale următoarelor acțiuni: Adobe, Apple, Autodesk, Cisco, Dell, Microsoft și 3M, acoperind perioada 16 Februarie 1990 – 18 Iunie 2009. Aceasta ne dă un total de 5044 de observații. Așa cum a fost menționat anterior, opțiunea pentru aceste acțiuni este justificată prin prisma corelațiilor (potențial) mari existente, fapt ce face ca cazul lor să fie unul ideal în aplicarea PCA. Totuși, cele șapte serii

de date sunt fundamental diferite, lucru care face interesantă izolarea efectelor fiecăreia în portofoliul format. Dar mai întâi să ne familiarizăm cu datele.

Atunci când urmărim estimarea parametrilor unui model compozit cu medie/varianță condițională, ne putem confrunta cu probleme de convergență. Astfel, estimarea, poate apărea ca reducându-și viteza sau să nu prezinte nici un fel de progres. Pentru evitarea acestor tipuri de dificultăți, se recomandă efectuarea unei analize premergătoare ('pre-fit'). Principalul scop al acesteia este acela de a atenua circumstanțele apariției oricărui tip de probleme de convergență, prin alegerea celui mai potrivit model în descrierea datelor. În cazul nostru, scopul este acela de a stabili, înainte de aplicarea modelului PC-GARCH, dacă datele ce constituie subiectul exercițiului empiric corespund unei aplicații cu un model de tip GARCH. Cu alte cuvinte, dorim să stabilim gradul de autocorelare din date.

Analiza de tip 'pre-fit' constituie din două etape:

- A. Reprezentarea grafică a seriilor de randamente ale acțiunilor și analiza funcției de autocorelație (ACF) și a celei de autocorelație parțială (PACF).
- B. Aplicarea testelor preliminare de heteroskedasticitate, ARCH (aparținând lui Engle) și de tip Q (aparținând lui Ljung, Box și Pierce).

Etapa A constituie din alte trei sub-etape:

A1. Întrucât modelarea GARCH presupune manipularea unor indicatori de creștere, trebuie să convertim prețurile acțiunilor în randamente realizate între un moment t și un moment $t+1$ (în cazul nostru de la o zi la alta). Graficele pot fi găsite în *Anexa 1*. Ele indică faptul că volatilitatea este concentrată pe perioade mici de timp, indicând posibile corelații între volatilitățile prezente și cele istorice.

A2. Verificăm dacă există corelație în fiecare din aceste șiruri de date. Graficele ACF (*Anexa 2*) și PACF (*Anexa 3*) indică câteva caracteristici generale cu privire la aceste câștiguri, în special dacă există vreo structură de corelație în media condițională. În cazul nostru particular, observăm că graficele ACF și PACF indică o oarecare autocorelație, însă argumentul autocorelației este încă insuficient argumentat la acest punct.

A3. Verificăm corelația în pătratele randamentelor (*Anexa 4*). Avem nevoie de aceasta deoarece, deși ACF câștigurilor observate indică o corelație relativ mică, ACF pătratelor randamentelor pot indica corelații și persistență semnificative în momentele de ordin doi. Verificăm acest lucru prin reprezentarea grafică a funcțiilor de autocorelație corespunzătoare pătratelor randamentelor.

Se poate observa că autocorelația a crescut pentru toate șocurile. De observat că ACF în toate graficele apare ca diminuându-se treptat, indicând posibilitatea ca procesul de varianță să fie aproape nonstaționar.

Se pot identifica concentrări de volatilitate în fiecare grup de grafice, pentru toate seriile de timp, lucru care indică faptul că acțiunile selectate sunt o alegere potrivită pentru folosirea PC-GARCH ca subiect al studiului empiric.

Etapă B constituie din aplicarea testelor ARCH și LBPQ.

Etapă de preestimare continuă cu detectarea și cuantificarea corelațiilor existente în șirurile de date. Deși graficele din etapă precedentă pot oferi indicii asupra existenței unei astfel de corelații, testele finale care pot stabili existența acestora sunt cele de tip ARCH și LBPQ. Utilizând testul LBPQ se poate verifica, cel puțin aproximativ, prezența oricărei corelații semnificative în randamentele acțiunilor, testate cu până la 20 de lag-uri ale funcției de autocorelare, la nivelul de semnificație 0.05. Respingerea sau acceptarea ipotezei nule este dată de vectorul de decizie H : 0 indică acceptarea ipotezei nule că 'fit-ul' modelului este adecvat (ceea ce înseamnă că nu există nici o corelație serială la numărul de lag-uri selectat), iar 1 înseamnă respingerea acesteia.

Rezultatele testului LBPQ pot fi consultate în *Anexa 5*. Se poate astfel verifica dacă există vreo corelație semnificativă în șirurile de date, până la 20 de lag-uri ale funcției ACF. Însă, deoarece suntem interesați mai ales în cât de mult datele mai recente influențează variația viitoare, vom aplica testele LBPQ și ARCH cu 7 lag-uri maxim, cu un α preselectat la 0.05.

Putem observa că cu excepția acțiunilor Apple, toate testele indică $H=1$ pentru majoritatea lag-urilor, cu toți parametrii (acolo unde vectorul de decizie este 1) mai mari decât valorile lor critice, ceea ce ne face să concluzionăm că respingem ipoteza nulă. Astfel, există corelație serială la numărul de lag-uri selectat. Păstrăm această concluzie ca o referință a existenței autocorelațiilor în date.

Testul Engle oferă suport prezenței efectelor GARCH în date, cum ar fi heteroskedasticitatea. Ca și în cazul LBPQ, H este un vector boolean de decizie: când este egal cu 0, implică inexistența vreunei corelații (nerespingerea ipotezei nule) iar când este 1 înseamnă că o corelație semnificativă există (respingerea ipotezei nule).

Din *Anexa 6* putem observa că respingem ipoteza nulă pentru toate acțiunile, astfel încât putem spune că avem corelație semnificativă. În cazul Apple, vectorul de decizie este 1, deși când am aplicat LBPQ am găsit acceptarea ipotezei nule. Combinația acestor două rezultate ne face să concluzionăm că avem suficientă corelație a datelor care să justifice aplicarea testului PC-GARCH.

După aplicarea testelor Ljung-Box-Pierce-Q și Engle pentru heteroskedasticitate se poate concluziona că toate cele șapte serii de date sunt heteroskedastice. Acest lucru indică faptul că seria de timp descrisă de fluctuația randamentelor acțiunilor, în fiecare din cele șapte cazuri, poate fi un caz ideal pentru tratamentul PC-GARCH. Lista cu codurile Matlab utilizate de-a lungul întregului exercițiu empiric se află în partea de anexă a tezei de doctorat.

Și cu aceasta terminăm partea de preestimare a modelului PC-GARCH. Înainte de a începe aplicarea modelului, în ceea ce urmează voi redefini problema în contextul specific al celor șapte acțiuni selectate.

C.7.3 Pregătirea datelor pentru PCA

Datele selectate conțin 5044 de observații ale randamentelor acțiunilor Adobe, Apple, Autodesk, Cisco, Dell, Microsoft și 3M. Vrem să găsim componentele principale. Deoarece fiecare componentă este o combinație liniară a variabilelor centrate, trebuie mai întâi să obținem aceste variabile centrate prin deducerea mediei din fiecare x_i . Astfel, vom calcula

media fiecărei serii de date și o vom extrage din x_i . Vom obține astfel $\mathbf{X} = \begin{pmatrix} x_1 - \bar{x}_1 \\ x_2 - \bar{x}_2 \\ x_3 - \bar{x}_3 \\ x_4 - \bar{x}_4 \\ x_5 - \bar{x}_5 \\ x_6 - \bar{x}_6 \\ x_7 - \bar{x}_7 \end{pmatrix}$

matricea variabilelor centrate, Pentru a obține matricea componentelor principale, vom

multiplica $\mathbf{X}$ cu matricea $\mathbf{A}$, unde $\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & a_{13} & a_{14} & a_{15} & a_{16} & a_{17} \\ a_{21} & a_{22} & a_{23} & a_{24} & a_{25} & a_{26} & a_{27} \\ a_{31} & a_{32} & a_{33} & a_{34} & a_{35} & a_{36} & a_{37} \\ a_{41} & a_{42} & a_{43} & a_{44} & a_{45} & a_{46} & a_{47} \\ a_{51} & a_{52} & a_{53} & a_{54} & a_{55} & a_{56} & a_{57} \\ a_{61} & a_{62} & a_{63} & a_{64} & a_{65} & a_{66} & a_{67} \\ a_{71} & a_{72} & a_{73} & a_{74} & a_{75} & a_{76} & a_{77} \end{pmatrix}$. Astfel,

vom defini $\mathbf{A}_{7,7}\mathbf{X}_{7,1} = \mathbf{P}_{7,1}$. Avem atunci $\mathbf{AX} = \mathbf{P} = \begin{pmatrix} p_1 \\ p_2 \\ p_3 \\ p_4 \\ p_5 \\ p_6 \\ p_7 \end{pmatrix}$. Vrem să găsim matricea $\mathbf{A}$ care,

când va fi multiplicată cu matricea variabilelor centrate $\mathbf{X}$, ne va da matricea ortogonală $\mathbf{P}$ cu care putem lucra (în fiecare celulă a lui $\mathbf{P}$ se va afla o componentă principală ce va fi o combinație liniară între variabilele centrate x și a). Dacă decidem să folosim un număr de componente principale mai mic decât numărul original de variabile, vom pierde ceva informație, dar vom păstra datele necorelate $\mathbf{P}$ care vor explica $\mathbf{Y}$ (vezi Alexander (2000) pentru detalii). Astfel, pentru a găsi $\mathbf{P}$, trebuie să găsim $\mathbf{A}$ care rezolvă $\mathbf{AX}=\mathbf{P}$ și vom impune condiția ortogonalității pentru $\mathbf{P}$, care este $Var(\mathbf{P}) = 0$.

C.7.3.1 Rezolvând ortogonalitatea

Prin definiție, matricea de varianță-covarianță $\mathbf{P}$ este egală cu $\mathbf{PP}'$. Folosind proprietatea că

$$(\mathbf{AB})' = \mathbf{B}'\mathbf{A}', \text{ găsim că } \text{Var}(\mathbf{P}) = \mathbf{PP}' = \mathbf{AX}(\mathbf{AX})' = \mathbf{AXX}'\mathbf{A}', \text{ unde } \mathbf{X} = \begin{pmatrix} x_1 - \bar{x}_1 \\ x_2 - \bar{x}_2 \\ x_3 - \bar{x}_3 \\ x_4 - \bar{x}_4 \\ x_5 - \bar{x}_5 \\ x_6 - \bar{x}_6 \\ x_7 - \bar{x}_7 \end{pmatrix} \text{ și } \mathbf{XX}'$$

$= \text{Var}(\mathbf{X})$. Denumim $\mathbf{XX}' = \text{Var}(\mathbf{X}) = \mathbf{\Omega}$, din care rezultă că $\text{Var}(\mathbf{P}) = \mathbf{PP}' = \mathbf{A} \mathbf{\Omega} \mathbf{A}'$. Deoarece una dintre problemele inițiale era că unele dintre elemente sunt corelate, vrem să găsim un $\mathbf{P}$ compus din elemente ortogonale. Dintr-o matrice mai mare $\mathbf{X}$, vrem să obținem matricea $\mathbf{P}$ de dimensiuni egale sau mai mici decât $\mathbf{X}$, care să aibe numai valori necorelate, fiecare element din $\mathbf{P}$ fiind o combinație liniară formată din elementele lui $\mathbf{X}$.

Pentru a înțelege mai bine termenul „elemente necorelate ale lui $\mathbf{P}$ ”, să presupunem $\mathbf{P} =$

$$\begin{pmatrix} p_1 \\ p_2 \\ p_3 \\ p_4 \\ p_5 \\ p_6 \\ p_7 \end{pmatrix}; \text{ atunci } \mathbf{P}' = (p_1 \ p_2 \ p_3 \ p_4 \ p_5 \ p_6 \ p_7), \text{ și}$$

$$\mathbf{PP}' = \text{Var}(\mathbf{P}) = \begin{pmatrix} p_1^2 & p_1p_2 & p_1p_3 & p_1p_4 & p_1p_5 & p_1p_6 & p_1p_7 \\ p_2p_1 & p_2^2 & p_2p_3 & p_2p_4 & p_2p_5 & p_2p_6 & p_2p_7 \\ p_3p_1 & p_3p_2 & p_3^2 & p_3p_4 & p_3p_5 & p_3p_6 & p_3p_7 \\ p_4p_1 & p_4p_2 & p_4p_3 & p_4^2 & p_4p_5 & p_4p_6 & p_4p_7 \\ p_5p_1 & p_5p_2 & p_5p_3 & p_5p_4 & p_5^2 & p_5p_6 & p_5p_7 \\ p_6p_1 & p_6p_2 & p_6p_3 & p_6p_4 & p_6p_5 & p_6^2 & p_6p_7 \\ p_7p_1 & p_7p_2 & p_7p_3 & p_7p_4 & p_7p_5 & p_7p_6 & p_7^2 \end{pmatrix} \text{ care este simetrică. În}$$

cazul nostru, p reprezintă σ . Ortogonalitatea lui $\mathbf{P}$ înseamnă că $p_i p_j = 0$, deoarece excludem orice corelație dintre varianțele p -urilor. Aceasta implică că

$\text{Var}(\mathbf{P}) = \text{diag}(p_1^2 \ p_2^2 \ p_3^2 \ p_4^2 \ p_5^2 \ p_6^2 \ p_7^2)$. Astfel vedem că matricea de varianță-covarianță a matricei elementelor ortogonale este o matrice diagonală. Din algebra matriceală, folosim rezultatul că matricea $\mathbf{A}$ este matricea vectorilor eigen unitari și ortogonali ai lui $\mathbf{\Omega}$.

C.7.3.2 Obținerea matricei componentelor principale

Să sumarizăm problema: vrem să folosim variabilele x_k pentru a explica variabilele y_k , dar variabilele x_k sunt prea multe (k este prea mare). Alegem să reducem k astfel că trebuie să alegem acei factori care explică cea mai mare parte a variației (sau cât mai mult din variație

pentru un k ales care face problema tractabilă). Căutăm așadar acea relație liniară a lui x_k care ne va întoarce acei factori principali p_l ortogonali ($l \leq k$).

În problema noastră, factorii p_m sunt noile variabile x_k , astfel încât trebuie să rearanjăm matricea $\mathbf{P}$ (mai exact variațiile σ^2) în ordine descrescătoare pentru a vedea care p_l sunt cei mai mari. Vom impune apoi condiția $\mathbf{P}=\mathbf{A}\mathbf{X}$ (unde $\mathbf{A}$ este matricea ponderilor factorilor iar $\mathbf{X}$ este matricea definită mai sus). În notație matriceală, aceasta devine

$$\mathbf{P} = \begin{pmatrix} a_{11} & a_{12} & a_{13} & a_{14} & a_{15} & a_{16} & a_{17} \\ a_{21} & a_{22} & a_{23} & a_{24} & a_{25} & a_{26} & a_{27} \\ a_{31} & a_{32} & a_{33} & a_{34} & a_{35} & a_{36} & a_{37} \\ a_{41} & a_{42} & a_{43} & a_{44} & a_{45} & a_{46} & a_{47} \\ a_{51} & a_{52} & a_{53} & a_{54} & a_{55} & a_{56} & a_{57} \\ a_{61} & a_{62} & a_{63} & a_{64} & a_{65} & a_{66} & a_{67} \\ a_{71} & a_{72} & a_{73} & a_{74} & a_{75} & a_{76} & a_{77} \end{pmatrix} \begin{pmatrix} x_1 - \bar{x}_1 \\ x_2 - \bar{x}_2 \\ x_3 - \bar{x}_3 \\ x_4 - \bar{x}_4 \\ x_5 - \bar{x}_5 \\ x_6 - \bar{x}_6 \\ x_7 - \bar{x}_7 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^7 a_{1i}(x_i - \bar{x}_i) \\ \sum_{i=1}^7 a_{2i}(x_i - \bar{x}_i) \\ \sum_{i=1}^7 a_{3i}(x_i - \bar{x}_i) \\ \sum_{i=1}^7 a_{4i}(x_i - \bar{x}_i) \\ \sum_{i=1}^7 a_{5i}(x_i - \bar{x}_i) \\ \sum_{i=1}^7 a_{6i}(x_i - \bar{x}_i) \\ \sum_{i=1}^7 a_{7i}(x_i - \bar{x}_i) \end{pmatrix}$$

în care a_{ij} ($1 \leq i, j \leq 7$) reprezintă ponderile factorilor. Avem astfel transformări liniare ale variabilelor x_k care ne dau factorii p_l , cu alte cuvinte am transformat x_k în p_l .

Aceasta înseamnă că

$$p_1 = a_{11}(x_1 - \bar{x}_1) + a_{12}(x_2 - \bar{x}_2) + a_{13}(x_3 - \bar{x}_3) + a_{14}(x_4 - \bar{x}_4) + a_{15}(x_5 - \bar{x}_5) + a_{16}(x_6 - \bar{x}_6) + a_{17}(x_7 - \bar{x}_7)$$

$$p_2 = a_{21}(x_1 - \bar{x}_1) + a_{22}(x_2 - \bar{x}_2) + a_{23}(x_3 - \bar{x}_3) + a_{24}(x_4 - \bar{x}_4) + a_{25}(x_5 - \bar{x}_5) + a_{26}(x_6 - \bar{x}_6) + a_{27}(x_7 - \bar{x}_7)$$

$$p_3 = a_{31}(x_1 - \bar{x}_1) + a_{32}(x_2 - \bar{x}_2) + a_{33}(x_3 - \bar{x}_3) + a_{34}(x_4 - \bar{x}_4) + a_{35}(x_5 - \bar{x}_5) + a_{36}(x_6 - \bar{x}_6) + a_{37}(x_7 - \bar{x}_7)$$

$$p_4 = a_{41}(x_1 - \bar{x}_1) + a_{42}(x_2 - \bar{x}_2) + a_{43}(x_3 - \bar{x}_3) + a_{44}(x_4 - \bar{x}_4) + a_{45}(x_5 - \bar{x}_5) + a_{46}(x_6 - \bar{x}_6) + a_{47}(x_7 - \bar{x}_7)$$

$$p_5 = a_{51}(x_1 - \bar{x}_1) + a_{52}(x_2 - \bar{x}_2) + a_{53}(x_3 - \bar{x}_3) + a_{54}(x_4 - \bar{x}_4) + a_{55}(x_5 - \bar{x}_5) + a_{56}(x_6 - \bar{x}_6) + a_{57}(x_7 - \bar{x}_7)$$

$$p_6 = a_{61}(x_1 - \bar{x}_1) + a_{62}(x_2 - \bar{x}_2) + a_{63}(x_3 - \bar{x}_3) + a_{64}(x_4 - \bar{x}_4) + a_{65}(x_5 - \bar{x}_5) + a_{66}(x_6 - \bar{x}_6) + a_{67}(x_7 - \bar{x}_7)$$

$$p_7 = a_{71}(x_1 - \bar{x}_1) + a_{72}(x_2 - \bar{x}_2) + a_{73}(x_3 - \bar{x}_3) + a_{74}(x_4 - \bar{x}_4) + a_{75}(x_5 - \bar{x}_5) \\ + a_{76}(x_6 - \bar{x}_6) + a_{77}(x_7 - \bar{x}_7)$$

Cunoaștem x_k , dar nu cunoaștem a_l . Ce rămâne de făcut este să găsim acele variabile a_l care vor da factorii ortogonali, deoarece variabilele a_l reprezintă ponderile fiecărei variabile x_k . Pentru aceasta, deoarece căutăm ortogonalitatea, vom impune restricția ca matricea de covarianță obținută să fie o matrice diagonală. După aceasta, vom reduce variabilele x_k la $p_1, p_2, \dots, p_7$. Odată ce introducem valorile x și y , programul ne va da ponderile factorilor (a) și valorile eigen (λ care este de fapt σ^2) care sunt obținute din condiția de ortogonalitate $\text{Var}(\mathbf{P})$

$$= 0. \text{ Vectorii eigen sunt de fapt coloanele matricei } \mathbf{A} \left(\mathbf{A} = \begin{pmatrix} \begin{matrix} \lambda_1 \\ \vdots \\ \vdots \\ \vdots \end{matrix} & \begin{matrix} \lambda_2 \\ \vdots \\ \vdots \\ \vdots \end{matrix} & \dots & \begin{matrix} \lambda_7 \\ \vdots \\ \vdots \\ \vdots \end{matrix} \end{pmatrix} \right). \text{ Ele}$$

Eigenvector1
Eigenvector 2
Eigenvector7

sunt ortogonale și au lungime de o unitate. După ce vom obține ponderile factorilor și valorile eigen, vom putea alege acei factori p (care acum vor fi necorelați din moment ce vom impune condiția ortogonalității) care vor arăta cea mai mare varianță (indicată de către valorile eigen).

Avem acum o matrice $\mathbf{P}$ ortogonală ale cărei valori sunt o combinație liniară a variabilelor independente din $\mathbf{X}$. Acum vom putea lucra cu $\mathbf{P}$ pentru a face previziuni asupra variațiilor lui $\mathbf{Y}$.

C.8 Implementarea PC-GARCH – algoritmul

Algoritmul se bazează pe lucrarea lui Burns (2005), dar va fi adaptat pe cerințele specifice ale acestei lucrări. Așa cum a fost descris în detaliu în secțiunile anterioare, Analiza Componentelor Principale va fi folosită pentru a permite obținerea unei versiuni tractabile a modelului multivariat GARCH. Această tractabilitate reiese din renunțarea la autocorelațiile dintre multiplele variații folosite, reducând setul de parametri la un număr utilizabil. În aceasta secțiune voi prezenta o scurtă trecere în revistă a algoritmului ce va fi folosit în acest scop.

Mai întâi, va fi estimat un model GARCH univariat pentru fiecare dintre cele șapte șiruri de date; acest pas stabilește mai întâi dacă un model multivariat GARCH este necesar. Dacă modelele univariate GARCH ar fi suficient de descriptive ale „realității”, erorile din aceste modele ar trebui să fie necorelate. O corelație puternică între erori implică prezența unui factor comun care influențează toate cele șapte șiruri de date simultan. În loc de a folosi autocorelațiile din același șir de date, putem exploata autocorelațiile dintre șirurile de date ce formează respectivul portofoliu. În termeni mai intuitivi, o corelație între erorile șirurilor de date (reprezentate de randamentele celor șapte acțiuni selectate) implică faptul că „există informație” în celelalte șiruri de date care poate fi folosită pentru a previziona volatilitatea fiecărei serii de timp. De amintit că GARCH este o tehnică care împarte varianțele în cele ce

se datorează autocorelațiilor (efecte din trecut) și inovații (erori, definite drept diferența dintre valorile observate și cele previzionate).

Astfel, o corelație între erori indică faptul că ceea ce modelul GARCH univariat presupune a fi inovații nu sunt cu adevărat inovații, întrucât pot fi explicate de mișcările din celelalte șiruri de date ale portofoliului.

Întrucât testul nostru indică faptul că un model GARCH multivariat este garantat în acest scenariu, următorul nostru pas este acela de a găsi șapte factori necorelați care influențează randamentele acțiunilor selecționate. De amintit din discuția teoretică anterioară faptul că din moment ce avem șapte variabile (care nu sunt coliniare deși sunt corelate), vom lucra într-un mediu multidimensional (cu șapte axe) în care fiecare dimensiune reprezintă randamentele acțiunilor selectate. Aceste șapte dimensiuni sunt, așa cum am văzut, extrem de corelate; deci neortogonale. Precum a fost menționat anterior, aceste variabile neortogonale dar foarte corelate sunt sursa dificultăților de tractabilitate și de aceea vrem să identificăm factorii ortogonali (necorelați) ce ar putea fi folosiți în mod convenabil în locul variabilelor inițiale.

Metoda PCA se aplică valorilor reziduale obținute în urma implementării GARCH; încercăm astfel să găsim șapte surse necorelate de „erori”, aceste „erori” fiind inovații obținute din aplicațiile precedente ale modelului GARCH univariat. În mod intuitiv, ceea ce încercăm aici este să izolăm cei șapte factori care determină inovațiile. Din moment ce încercăm să găsim factorii care influențează randamentele unor acțiuni aparținând aceleiași țări, ne așteptăm să identificăm un factor al cărui efect asupra randamentelor este semnificativ, și alți factori specifici fiecărui șir de date, cu o influență moderată.

Rezultatul aplicației cu Analiza Componentelor Principale este matricea coeficienților. Această matrice va fi utilizată pentru estimarea noilor valori reziduale corespunzătoare fiecărei componente principale. Pentru motive pe care le voi detalia în prezentarea ce urmează, nu voi exclude nici o componentă principală, ci le voi utiliza pe toate șapte. Aceste noi valori reziduale sunt astfel ortogonale una alteia, iar aplicarea modelului multivariat GARCH asupra lor este echivalentă cu efectuarea simultană a șapte aplicații cu modele univariate GARCH. Această reducere a unui model multivariat GARCH la un set de modele univariate GARCH preprezintă motivul cheie al popularității tehnicii PC-GARCH. Modelele univariate GARCH vor fi aplicate fiecărui șir din aceste variabile reziduale. În mod intuitiv, ceea ce a fost înainte „neexplicat” acum devine „explicat” pe baza celor șapte factori ortogonali. Însă, în mod clar, ținta noastră a fost aceea de a obține un model GARCH al volatilităților randamentelor și nu un model GARCH al valorilor reziduale transformate. Astfel, trebuie să transformăm aceste modele GARCH înapoi în spațiul volatilităților variabilelor inițiale. Acest lucru este relativ ușor de îndeplinit: observăm că prin înmulțirea în partea stângă cu inversul matricei coeficienților și în partea dreaptă cu matricea coeficienților obținem matricea de varianță-covarianță originală (în acest caz, ea va fi un set format din șapte modele GARCH). Voi explica toate aceste etape în detaliu în secțiunea ce urmează.

C.8.1 Pasul 1: Estimarea modelelor univariate GARCH

Așa cum a fost menționat anterior, primul pas în aplicațiile cu algoritmul PC-GARCH este testarea inițială a modelului univariat GARCH și verificarea necesității de a adăuga variabile suplimentare.

Raționamentul este mai degrabă de ordin practic: utilizarea unui model cât mai simplu dacă se dovedește a fi suficient de bun, unde măsura în care acesta se dovedește a fi corespunzător este stabilită în funcție de cerințele utilizatorului. Astfel, la acest nivel, se încearcă utilizarea celui mai bun model univariat GARCH posibil. Aceasta înseamnă că coordonatele p și q ale modelului $GARCH(p,q)$ trebuie selectate în așa fel încât să optimizeze compensarea făcută între parametrii extra și predictibilitatea suplimentară realizată. Selecția variabilelor p și q este optimizată independent de cea a celorlalte modele luate în considerație.

Deoarece scopul este acela de a ilustra modul de funcționare și avantajele modelului PC-GARCH, alegem pur și simplu un model $GARCH(1,1)$ și îl aplicăm șirurilor de randamente. Rezultatele obținute din aplicațiile cu modelele $GARCH(1,1)$ sunt prezentate în tabelele *Anexei 7*. De amintit faptul că modelul $GARCH(1,1)$ are forma $y_t = C + \varepsilon_t$, $\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \beta_1 \varepsilon_{t-1}^2$.

Observăm din tabelele *Anexei 7* faptul că respingem ipoteza nulă conform căreia α_0 și α_1 sunt independent egale cu zero (întrucât valorile t se află în intervalul ± 1.96 , astfel că ne aflăm în zona de rejecție). Cu alte cuvinte, este potrivit să se modeleze seriile de timp ale volatilităților cu un model de tip $GARCH(1,1)$. Facem o pauză pentru a considera „efectul vizual” al decompoziției $GARCH(1,1)$; voi compara ulterior această decompoziție cu decompoziția realizată din procedura PC-GARCH.

C.8.2 Pasul al doilea: Obținerea valorilor reziduale din modelul $GARCH(1,1)$ și standardizarea acestora

În secțiunea anterioară au fost obținute modelele $GARCH(1,1)$ pentru Adobe, Apple, Autodesk, Cisco, Dell, Microsoft și 3M după cum urmează:

ADOBE:

$$y_t = 12.06 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 3.06 \times 10^{-6} + 0.971 \sigma_{t-1}^2 + 0.028 \varepsilon_{t-1}^2$$

APPLE:

$$y_t = 18.09 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 52.95 \times 10^{-6} + 0.868\sigma_{t-1}^2 + 0.084\varepsilon_{t-1}^2$$

AUTODESK:

$$y_t = 14.51 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 62.19 \times 10^{-6} + 0.838\sigma_{t-1}^2 + 0.102\varepsilon_{t-1}^2$$

CISCO:

$$y_t = 19.30 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 9.17 \times 10^{-6} + 0.920\sigma_{t-1}^2 + 0.071\varepsilon_{t-1}^2$$

DELL:

$$y_t = 11.32 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 3.59 \times 10^{-6} + 0.950\sigma_{t-1}^2 + 0.0486\varepsilon_{t-1}^2$$

MICROSOFT:

$$y_t = 10.01 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 6.41 \times 10^{-6} + 0.920\sigma_{t-1}^2 + 0.069\varepsilon_{t-1}^2$$

3M:

$$y_t = 3.89 \times 10^{-4} + \varepsilon_t$$

$$\sigma_t^2 = 2.66 \times 10^{-6} + 0.957\sigma_{t-1}^2 + 0.031\varepsilon_{t-1}^2$$

Pentru fiecare zi a eșantionului de 5044 de observații, calculăm previziunea volatilităților și o denumim σ_t . Folosim această previziune de varianță pentru a obține valorile reziduale standardizate ale randamentelor zilnice. Cu alte cuvinte, calculăm $\frac{y_t - \bar{y}_t}{\sigma_t}$, întrucât pentru fiecare t cunoaștem randamentul y_t . Astfel, vom avea acum o matrice a valorilor reziduale standardizate **R**. Această matrice este de dimensiunea 5044×7 (zile $\times$ numărul acțiunilor). Dacă modelul univariat GARCH(1,1) ar fi o „descriere adecvată” a „realității”, am găsi faptul ca coloanele lui **R** au medie zero (ceea ce avem prin construcția modelului), și o varianță de unu (care nu este necesar să fie adevărată, deoarece folosim estimatorul previziunii varianței, și nu varianța reală) și covarianța dintre rânduri să fie zero (ceea ce înseamnă că nu sunt „factori comuni” în afara explicațiilor oferite de autocovarianța valorilor reziduale zilnice).

Acum suntem pregătiți pentru analiza post-estimare. În această parte vom compara mai întâi valorile reziduale, deviațiile condiționale standard și randamentele, după care vom obține grafice și vom compara corelația inovațiilor standard. În final, vom cuantifica și compara corelația valorilor reziduale standardizate.

Analiza post-estimare:

1. Comparația valorilor reziduale, a deviațiilor condiționale standard și a randamentelor, pentru a se investiga dacă inovațiile obținute prezintă în continuare concentrații ale varianțelor.

Din inspecția vizuală a graficelor *Anexei 8*, putem observa volatilitatea concentrată atât în cazul randamentelor, cât și al inovațiilor. Așa cum am menționat anterior, vrem să vedem dacă inovațiile randamentelor celor șapte acțiuni selectate sunt necorelate, lucru care ne va sugera necesitatea unei aplicații cu modelul PC-GARCH. Ca un indiciu al corelațiilor lor, observăm în graficele de mai sus faptul că inovațiile variază aproximativ în jurul aceluiași date, datorită probabil unor factori comuni care le influențează pe toate. De asemenea, putem observa că, pentru fiecare acțiune, $\beta_1 + \alpha_1$ este foarte aproape de 1, ceea ce înseamnă că este foarte aproape de limita integrată, nonstaționară, dată de restricția unui model GARCH clasic:

$$\sum_{i=1}^{\max(m,s)} (\alpha_i + \beta_i) < 1.$$

2. Realizarea graficelor și comparația corelațiilor pentru inovațiile standardizate.

Am văzut ca inovațiile obținute anterior afișează concentrații de volatilitate. Dar dacă reprezentăm grafic inovațiile standardizate (inovații divizate de deviația condițională standard), ele vor apărea în general stabile cu o concentrare moderată (*Anexa 9*).

De asemenea, dacă reprezentăm grafic funcția de autocorelație a pătratelor inovațiilor standardizate, nu vom mai găsi nici o altă corelație (*Anexa 10*). Mai mult, dacă vom compara funcția de autocorelație a pătratelor inovațiilor standardizate din aceste figuri cu aceeași funcție a pătratelor randamentelor obținute la început, vom vedea faptul că acest model GARCH explică suficient heteroskedasticitatea din randamentele brute.

3. Cuantificarea și comparația corelației inovațiilor standardizate. La această etapă comparăm rezultatele testelor LBPQ și ARCH aplicate valorilor reziduale standardizate cu rezultatele aceluiași teste efectuate în analiza de pre-estimare. Acest lucru ne va indica dacă modelul GARCH a tratat corespunzător datele (*Anexa 11 și Anexa 12*).

Deși în analiza de pre-estimare ambele teste (în cazul testului LBPQ a existat totuși o excepție) indicau respingerea ipotezei nule, vom găsi acum faptul că atunci când folosim

inovațiile standardizate, aceleași teste indică acceptarea ($H=0$) aceleiași ipoteze nule. Aceste rezultate confirmă puterea explicativă a modelului standard și existența efectelor GARCH.

Avem așadar efecte GARCH și de asemenea corelații între inovații, care însă dispar după tratarea datelor. În concluzie, modelul GARCH este un model potrivit pentru a fi folosit în explicarea varianțelor celor șapte șiruri de date. Astfel, alegerea noastră intuitivă pentru cele șapte acțiuni este justificată, și putem astfel să ne îndreptăm către următoarea etapă.

C.8.3 Pasul al treilea: Analiza componentelor principale ale valorilor reziduale standardizate

Am văzut mai sus detalii ale metodei PCA, astfel că ne vom opri în continuare doar la raportarea principalelor rezultate. Matricea valorilor reziduale standardizate va fi matricea căreia i se va aplica PCA, deoarece dorim să identificăm cauzele comune ce determină faptul că modelul GARCH(1,1) nu explică în totalitate inovațiile.

Aplicăm Analiza Componentelor Principale inovațiilor standardizate. Obținem șapte combinații liniare, ortogonale, ale valorilor standardizate reziduale (*Anexa 13a*). De asemenea, programul Matlab produce un tabel suplimentar (numit „latent”) al valorilor eigen, pe baza căruia putem calcula puterea asociată fiecărei astfel de valori, reprezentând procentul din variație explicat de fiecare variabilă (*Anexa 13b*).

Observăm că cea mai mare parte a varianței este explicată de prima componentă principală, la care fluctuația de volatilitate a randamentului fiecărei acțiuni contribuie cu o magnitudine relativ egală. Acest lucru se află în concordanță cu intuiția inițială conform căreia, din moment ce toate acțiunile sunt tranzacționate în Statele Unite, există un factor comun care le influențează pe toate în aceeași direcție.

Putem observa că $P1$ ($=0.3793 \cdot \text{inovația standardizată a Adobe} + 0.3639 \cdot \text{inovația standardizată a Apple} + 0.3448 \cdot \text{inovația standardizată a Autodesk} + 0.4337 \cdot \text{inovația standardizată a Cisco} + 0.4022 \cdot \text{inovația standardizată a Dell} + 0.4201 \cdot \text{inovația standardizată a Microsoft} + 0.2804 \cdot \text{inovația standardizată a 3M}$) este prima componentă principală, care explică aproape 43% din varianța inovațiilor standardizate. Al doilea factor explică aproape 12% din varianța valorilor standardizate reziduale – observăm că acesta este influențat pozitiv de către Apple, Cisco, Dell și Microsoft, dar negativ de către Adobe, Autodesk și 3M. Al treilea factor explică numai 11% din varianța valorilor reziduale standardizate și acesta pare a fi influențat pozitiv de Adobe și Autodesk și negativ de Apple, Cisco, Dell, Microsoft și 3M. Restul componentelor principale au o pondere mai mică de 10% fiecare.

Astfel obținem, în ordine descrescătoare, șapte componente principale care influențează inovațiile. Însă vedem că ele nu sunt cu adevărat inovații: cea mai mare parte a acestei inovații este determinată de un factor comun major. Am putea alege la acest punct să reținem doar un factor principal care explică aproximativ 43% din așa-numitele inovații, și să ignorăm celelalte șase. Dar, ignorarea unui factor principal poate conduce ocazional la

rezultate neconcludente din moment ce nu vom putea garanta faptul că matricea de varianță-covarianță obținută va fi pozitiv definită (vezi Alexander (2000)).

Deoarece în acest caz particular nu avem decât șapte variabile, putem considera toți factorii în vederea asigurării eliminării oricăror posibile erori sau neconcludențe.

C.8.4 Pasul patru: Aplicarea modelului GARCH(1,1) asupra componentelor principale

Pornind de la forma unui model GARCH(1,1) $y_t = C + \varepsilon_t$, $\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \beta_1 \varepsilon_{t-1}^2$, aplicăm acest model asupra componentelor principale obținute. Rezumatele obținute pot fi regăsite summarize în *Anexa 14*. Astfel, avem un model GARCH care previzionează volatilitățile celor șapte componente principale. Însă, scopul nostru este acela de a obține modele de previzionare a volatilității pentru serii de randamente, nu pentru factorii principali. Vom vedea faptul că acest lucru va fi realizat printr-o simplă transformare liniară în secțiunea următoare.

C.8.5 Pasul cinci: obținerea modelului GARCH al randamentelor acțiunilor

Observăm că modelele GARCH(1,1) obținute anterior sunt pentru componentele principale. De exemplu, $\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \beta_1 \varepsilon_{t-1}^2$ ne dă previziunea volatilității fiecărei componente principale. Întrucât aceste șapte componente sunt ortogonale una alteia, putem scrie matricea varianței-covarianței precum o matrice diagonală. Cu alte cuvinte, amintind de discuția de mai devreme, vom utiliza ecuația (2): $\Lambda = P'P = A'X'XA = A'QA$. Avem acum Λ care consistă din previziunile de volatilitate ale celor șapte componente principale. Astfel, o simplă transformare liniară prin multiplicarea în partea stângă a previziunilor cu matricea A și multiplicarea în partea dreaptă cu A' va obține previziunile de volatilitate ale celor șapte serii de timp. Cele șapte ecuații obținute sunt după cum urmează:

$$\sigma_t^2 = 37.66 \times 10^{-2} + \begin{pmatrix} 14.21 \times 10^{-2} \\ 0.07 \times 10^{-2} \\ 6.36 \times 10^{-2} \\ 12.01 \times 10^{-2} \\ 0 \\ 7.45 \times 10^{-2} \\ 0.65 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.14 \times 10^{-2} \\ 0.02 \times 10^{-2} \\ 0.18 \times 10^{-2} \\ 0.93 \times 10^{-2} \\ 1.47 \times 10^{-2} \\ 0.69 \times 10^{-2} \\ 0.07 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 1: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor ADOBE.

$$\sigma_t^2 = 28.26 \times 10^{-2} + \begin{pmatrix} 13.08 \times 10^{-2} \\ 2.70 \times 10^{-2} \\ 6.06 \times 10^{-2} \\ 29.02 \times 10^{-2} \\ 0 \\ 4.73 \times 10^{-2} \\ 0.04 \times 10^{-2} \end{pmatrix} \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.13 \times 10^{-2} \\ 0.59 \times 10^{-2} \\ 0.17 \times 10^{-2} \\ 2.24 \times 10^{-2} \\ 0.50 \times 10^{-2} \\ 0.44 \times 10^{-2} \\ 0.44 \times 10^{-4} \end{pmatrix} \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 2: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor APPLE.

$$\sigma_t^2 = 36.49 \times 10^{-2} + \begin{pmatrix} 11.74 \times 10^{-2} \\ 0.23 \times 10^{-2} \\ 34.16 \times 10^{-2} \\ 0.49 \times 10^{-2} \\ 0 \\ 0.18 \times 10^{-2} \\ 0.03 \times 10^{-2} \end{pmatrix} \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.11 \times 10^{-2} \\ 0.05 \times 10^{-2} \\ 0.95 \times 10^{-2} \\ 0.04 \times 10^{-2} \\ 0.90 \times 10^{-2} \\ 0.02 \times 10^{-2} \\ 0.38 \times 10^{-4} \end{pmatrix} \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 3: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor AUTODESK.

$$\sigma_t^2 = 10.12 \times 10^{-2} + \begin{pmatrix} 18.58 \times 10^{-2} \\ 1.03 \times 10^{-2} \\ 0.37 \times 10^{-2} \\ 4.15 \times 10^{-2} \\ 0 \\ 2.28 \times 10^{-2} \\ 50.33 \times 10^{-2} \end{pmatrix} \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.18 \times 10^{-2} \\ 0.22 \times 10^{-2} \\ 0.01 \times 10^{-2} \\ 0.32 \times 10^{-2} \\ 0.10 \times 10^{-2} \\ 0.21 \times 10^{-2} \\ 5.60 \times 10^{-2} \end{pmatrix} \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 4: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor CISCO.

$$\sigma_t^2 = 16.17 \times 10^{-2} + \begin{pmatrix} 15.98 \times 10^{-2} \\ 2.37 \times 10^{-2} \\ 5.08 \times 10^{-2} \\ 5.78 \times 10^{-2} \\ 0 \\ 38.39 \times 10^{-2} \\ 2.91 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.15 \times 10^{-2} \\ 0.51 \times 10^{-2} \\ 0.14 \times 10^{-2} \\ 0.45 \times 10^{-2} \\ 0.16 \times 10^{-2} \\ 3.57 \times 10^{-2} \\ 0.32 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 5: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor DELL.

$$\sigma_t^2 = 13.55 \times 10^{-2} + \begin{pmatrix} 17.43 \times 10^{-2} \\ 0.34 \times 10^{-2} \\ 0.60 \times 10^{-2} \\ 8.44 \times 10^{-2} \\ 0 \\ 22.47 \times 10^{-2} \\ 23.38 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.17 \times 10^{-2} \\ 0.07 \times 10^{-2} \\ 0.02 \times 10^{-2} \\ 0.65 \times 10^{-2} \\ 0.22 \times 10^{-2} \\ 2.09 \times 10^{-2} \\ 2.60 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 6: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor MICROSOFT.

$$\sigma_t^2 = 38.49 \times 10^{-2} + \begin{pmatrix} 7.77 \times 10^{-2} \\ 34.09 \times 10^{-2} \\ 4.28 \times 10^{-2} \\ 0.02 \times 10^{-2} \\ 0 \\ 0.04 \times 10^{-2} \\ 0.09 \times 10^{-2} \end{pmatrix} \cdot \begin{pmatrix} (\sigma_{t-1}^{P_1})^2 \\ (\sigma_{t-1}^{P_2})^2 \\ (\sigma_{t-1}^{P_3})^2 \\ (\sigma_{t-1}^{P_4})^2 \\ (\sigma_{t-1}^{P_5})^2 \\ (\sigma_{t-1}^{P_6})^2 \\ (\sigma_{t-1}^{P_7})^2 \end{pmatrix} + \begin{pmatrix} 0.07 \times 10^{-2} \\ 7.39 \times 10^{-2} \\ 0.12 \times 10^{-2} \\ 0.15 \times 10^{-4} \\ 0.03 \times 10^{-2} \\ 0.36 \times 10^{-4} \\ 0.98 \times 10^{-4} \end{pmatrix} \cdot \begin{pmatrix} (\varepsilon_{t-1}^{P_1})^2 \\ (\varepsilon_{t-1}^{P_2})^2 \\ (\varepsilon_{t-1}^{P_3})^2 \\ (\varepsilon_{t-1}^{P_4})^2 \\ (\varepsilon_{t-1}^{P_5})^2 \\ (\varepsilon_{t-1}^{P_6})^2 \\ (\varepsilon_{t-1}^{P_7})^2 \end{pmatrix}$$

Formula 7: Modelul multivariat PC-GARCH al randamentelor zilnice ale acțiunilor 3M.

Aceste ecuații pot fi folosite în următorul mod:

1. Prin intermediul matricei componentelor principale se vor calcula cei șapte factori principali.

2. Se calculează volatilitatea și inovația asociate randamentelor componentelor principale.
3. Se înlocuiesc valorile calculate mai sus în modelul multivariat GARCH corespunzător, pentru obținerea previziunilor de volatilitate.

C.9 Concluzii privind utilizarea modelului PC-GARCH

Am văzut că modelul PC-GARCH este o metodă utilă de a reduce dimensionalitatea problemei multivariate GARCH și de a obține estimatori robuști și stabili folosind componente principale ortogonale. Întrucât am menționat deja multiplele sale avantaje, aș dori să concluzionez cu o dovadă vizuală a faptului că „inovația” pe care un model GARCH(1,1) o produce nu este într-adevăr inovație. Pentru acest scop, prezint decompoziția volatilităților randamentelor celor șapte acțiuni (aparținând companiilor Adobe, Apple, Autodesk, Cisco, Dell, Microsoft și 3M) după implementarea PC-GARCH, în graficele *Anexei 15*. Observăm o diferență semnificativă între graficele inovațiilor prezentate în capitolele *B.8.2* și *B.8.5*. Ceea ce este ușor observabil este faptul că maximele de volatilitate (în special în perioadele de turbulență maximă întâmplare în 1993, 1995, 2006, 2008 și 2009) nu mai sunt acum considerate drept „inovații” ci sunt mai degrabă explicate de salturi simultane ale inovațiilor celorlalte variabile. Astfel, inovațiile sunt considerate „adevărate inovații” care ar putea fi explicate de ceilalți factori. Totuși, fiecare model poate fi îmbunătățit însă câștigul în calitate se realizează cu un anumit cost. Unul dintre aceste costuri este acela al identificării modelului potrivit eșantionului de date ales, ceea ce face ca performanța măsurată prin eșantioane separate ('out-of-sample') să fie crucială în privința identificării modelului corespunzător.

Scopul părții empirice a fost acela de a evidenția superioritatea modelului PC-GARCH în termeni ai raportului calitate a rezultatelor / cost implicat atunci când se lucrează cu eșantioane largi de date. S-a dovedit empiric cum se pot obține matrici extinse GARCH folosind tehnici de estimări univariate cu GARCH aplicate componentelor principale ale seriilor originale de randamente. Avantajele unei astfel de metode sunt, după cum urmează:

- Minimizează eforturile computaționale (prin transformarea modelelor multivariate GARCH în modele univariate), prin reducerea semnificativă a timpului computațional și eliminarea oricărei probleme ce se poate ivi din manipulări complexe de date;
- Asigură un control strict al cantității de „zgomot” prin reducerea numărului de variabile la un număr mai mic de componente principale. Aceasta se poate dovedi benefică deoarece asigură estimatori de corelație mai stabili.
- O astfel de metodă produce volatilități și corelații pentru toate variabilele din sistem, inclusiv pentru acelea pentru care estimarea directă cu GARCH este potențial dificilă.

Multitudinea de avantaje ale tehnicilor GARCH de previzionare a volatilității, printre care flexibilitatea și acuratețea, le plasează într-o poziție unică, aceea de a îndeplini multe dintre nevoile de estimare ale practicienilor, în special în activitățile de management al riscului sau de tranzacționare. Acest lucru însă poate fi afectat dacă o metodă fezabilă care să ajute la

manipularea a unor matrici mari de covarianță nu este găsită sau nu este corespunzător implementată. Date fiind dificultățile considerabile ce pot apărea în estimarea datelor când se lucrează cu astfel de matrici extinse de date, contribuția modelului PC-GARCH devine semnificativă. Construit pentru a captura variația unui eșantion de randamente prin intermediul câtorva factori ortogonali, atribuind restul de variație factorilor asociați „zgomotului”, utilizarea analizei componentelor principale permite transformarea procedurilor de optimizare în serii de timp univariate. Aceasta permite reducerea densității computaționale, întrucât matricea de varianță-covarianță poate fi obținută din simple transformări liniare ale varianțelor factorilor. Folosit în diverse exerciții empirice, PC-GARCH nu a fost găsit ca funcționând defectuos în nici unul dintre acestea. Superioritatea sa a fost evidentă în fiecare dintre aceste cazuri, pornind de la serii de timp bivariate sau trivariate până la cele multivariate conținând câteva mii de variabile.

C.10 Remarci finale

Am văzut în prezenta teză cum riscul poate fi evaluat dintr-o perspectivă dublă, din punctul de vedere al unei companii care intenționează să investească în străinătate. Am discutat prin urmare riscurile de tip endogen (sau dominant endogene) și le-am concentrat în jurul principalei stringențe a unei afaceri nou înființate în străinătate, aceea de a dobândi acces la surse de finanțare. Am discutat riscul de credit și riscul asumat (de contrapartidă), de asemenea modul în care riscul sistemic poate afecta o companie, în special atunci când finanțarea este făcută exclusiv prin emisiuni de titluri. Atunci când astfel de emisiuni au loc, un rol principal în succesul acestora revine agențiilor de rating care evaluează perspectivele companiei în ceea ce privește capacitatea acestora de rambursare a titlurilor.

Riscul a fost de asemenea grupat într-o categorie a cărei trăsături definitorii este exogeneitatea. Au fost astfel considerate riscurile asociate sectorului în care urmează să se investească, gradul de risc fiind echivalent, din această perspectivă, cu riscul de cădere a pieței. S-a discutat cât de riscant este un sector din perspectiva fluctuației randamentelor date de variația prețurilor acțiunilor. Această fluctuantă a fost denumită „volatilitate” și a fost evaluată din punct de vedere econometric. A fost sugerat faptul că cea mai bună modalitate de a evalua riscul unui sector este de a forma un portofoliu/grup de acțiuni aparținând celor mai relevante companii activând în același sector, și de a modela și previziona volatilitatea randamentelor portofoliului astfel creat. Problema devine complicată din cauza subiectivității în alegerea modelului, care provine din lipsa existenței unui consens în literatură în ceea ce privește identificarea unui model capabil să calculeze cei mai buni estimatori. Mai mult, din moment ce considerăm un portofoliu cu serii puternic corelate, un model multivariat trebuie aplicat, fapt ce determină ca problema să fie dificilă de rezolvat empiric. Am sugerat că pentru portofoliile formate din sute și mii de variabile, Principal Component-GARCH este modelul potrivit de utilizat pentru previzionarea volatilității.

D. Bibliografie

1. Abreu D. și Brunnermeier M. (2003) Bubbles and Crashes, *Econometrica*, Vol. 71(1), pg. 173-204.
2. Aharony J. și Swary I. (1996) Additional Evidence on the Information-Based Contagion Effects of Bank Failures, *Journal of Banking and Finance*, Vol 20(1), pg. 57-69.
3. Akgiray V. (1989) Conditional heteroskedasticity in time series of stock returns: Evidence and forecasts, *Journal of Business*, Vol. 62, pg. 55-80.
4. Albu L. L. (2003) Short-term forecast, *Romanian Journal for Economic Forecasting*, Vol. 4, Ediția 1, pg. 197-199.
5. Alexander C. O. (1998) Volatility and correlation: methods, models and applications, *Risk management and analysis: measuring and modeling financial risk*, Wileys.
6. Alexander C. O. (2000) A primer on the Orthogonal GARCH model, retrieved March 15th, from <http://www.ismacentre.rdg.ac.uk/pdf/orthogonal.pdf>.
7. Allen F. și Gale D. (1998) Optimal Financial Crises, *Journal of Finance*, Vol. 47, pg. 1245-84.
8. Allen F. și Gale D. (2000) Bubbles and Crises, *The Economic Journal*, Vol. 110, pg. 236-255.
9. Andersen T. G. și Bollerslev T. (1998a) Answering the skeptics: Yes, standard volatility models do provide accurate forecasts, *International Economic Review*, Vol. 39, Nr. 4, pg. 885-905.
10. Andersen T. G., Bollerslev T., Christoffersen P. F. și Diebold F. X. (2005) Volatility Forecasting, *PIER (Penn Institute for Economic Research) Working Paper 05-01*, pg. 1-110

11. Andersen T., Bollerslev T., Diebold F. X. și Labys P. (2003) Modeling and forecasting realized volatility, *Econometrica*, Vol. 71, pg. 529-626.
12. Andersen T. G., Bollerslev T. și Lange S. (1999) Forecasting financial market volatility: Sample frequency vis-à-vis forecast horizon, *Journal of Empirical Finance*, Vol. 6(5), pg. 457-477.
13. Andersen T. G., Bollerslev T. G. și Meddahi N. (2004) Analytic Evaluation of Volatility Forecasts, *International Economic Review*, Vol. 45(4), pg. 1079-1110.
14. Andreica C., Andreica M., Andreica R., Miclaus I. și Ungureanu M. (2007) Conclusions on using the statistical methods in forecasting the structure evolution of an economic indicator system, *Economic Computation and Economics Cybernetics Studies and Research*, Vol. 41 (1-2), pg. 147-157.
15. Andreica M. (2006) A model to forecast the evolution of the structure of a system of economic indicators, *Romanian Journal for Economic Forecasting*, Vol. 7 (1), pg. 65-73.
16. Angelini P., Maresca G. și Russo D. (1996) Systemic Risk in the Netting System, *Journal of Banking and Finance*, Vol. 20(5), pg. 853–868
17. Armendàriz de Aghion B. (1995) On the Design of a Credit Agreement with Peer Monitoring, *Journal of Development Economics*, Vol. 60, pg. 79-104.
18. Balaban E. (2002) Comparative forecasting performance of symmetric and asymmetric conditional volatility models of an exchange rate, *University of Edinburgh Center for Financial Markets Research Working Paper*, Nr. 02.06.
19. Balaban E. și Bayar A. (2005) Stock Returns and Volatility: Empirical Evidence from Fourteen Countries, *applied Economic Letters*, 12, pg. 603-611.
20. Balaban E., Bayar A. și Faff R. (2004) Forecasting Stock Market Volatility: Further International Evidence, *The European Journal of Finance*, Vol. 12, Ediția 2, pg. 171-188.

21. Barucci E. și Renò (2002) On Measuring Volatility and the GARCH Forecasting Performance, *Journal of International Financial Markets, Institutions and Money*, Vol. 12, Ediția 3, pg. 183-200.
22. Bartholomew P. și Whalen G. (1995) *Fundamentals of Systemic Risk*. In *Research in Financial Services: Banking, Financial Markets, and Systemic Risk*, Vol. 7, edited by George G. Kaufman, 3–17, Greenwich, Conn.: JAI.
23. Basile A. și Joyce J. (2001) Asset Bubbles, Monetary Policy and Bank Lending in Japan: An Empirical Investigation, *Applied Economics*, Vol. 33, pg. 1737-1744.
24. Benston G., Eisenbeis R., Horvitz P., Kane E. și Kaufman G. (1986) *Perspectives on Safe and Sound Banking*, Cambridge, Mass.: MIT Press.
25. Benston G. și Kaufman G. (1995) Is the Banking Payments System Fragile?, *Journal of Financial Services Research*, Vol. 9, pg. 209–240.
26. Bera A. K. și Higgins M. L. (1993) ARCH Models: Properties, Estimation and Testing, *Journal of Economic Surveys*, Vol. 7, Nr. 4, pg. 305-62.
27. Bhattacharya S. și Fulghieri P. (1994) Uncertain Liquidity and Interbank Contracting, *Economics Letters*, Vol. 44(3), pg. 287-294.
28. Biscarri J. G. (2008) Volatility and Financial Time Series, Class notes of “Time Series in Finance”.
29. Black F. (1976) Studies of stock price volatility changes, *Proceedings of the American Statistical Association*, Business and Economic Statistics Section, pg. 177-181.
30. Bluhm H. și Yu J. (2001) Forecasting Volatility: Evidence from the German Stock Market, *Economics Working Papers*, The University of Auckland
31. Bollerslev T. (1986) Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, Vol. 31, pg. 307-327.

32. Bollerslev T., Chou R. Y. și Kroner K. F. (1992) ARCH Modeling in Finance, *Journal of Econometrics*, Ediția 52, pg. 5-59.
33. Bollerslev T., Engle R. F. și Nelson D.B. (1994) ARCH Models, *Handbook of Econometrics*, Vol. IV (eds. R.F. Engle and D. McFadden), Amsterdam: Elsevier Science B. V.
34. Bollerslev T. G. și Forsberg L. E. (2002) Bridging the Gap Between the Distribution of Realized (ECU) Volatility and ARCH Modeling (of the Euro): The GARCH-NIG Model, *Journal of Applied Econometrics*, Vol. 17, pg. 535-548.
35. Bollerslev T. G. și Wright J. (2001) Volatility Forecasting, High-Frequency Data, and Frequency Domain Inference, Bollerslev, *Review of Economics and Statistics*, Vol. 83, pg. 596-602.
36. Bollerslev T. și Zhou H. (2007) Expected Stock Returns and Variance Risk Premia, *Board of Governors of the Federal Reserve System (U.S.): Finance and Economics Discussion Series*, Nr. 2007-11.
37. Bordo M., Eichengreen B., Klingebiel D. și Martinez-Peria M. S. (2000) Is the crisis problem growing more severe?, *Economic Policy*, Vol. 16(32), pg. 51-82.
38. Borrus A., McNamee M. și Timmons H. (2002) The Credit-Raters: How They Work and How They Might Work Better, *The Business Week*. Retrieved on October 28th 2008 at: http://www.businessweek.com/magazine/content/02_14/b3777054.htm
39. Box G. E. P., Jenkins G. M. și Reinsel G. C. (1994) *Time Series Analysis: Forecasting and Control*, 3RD Ed., Prentice Hall, Inc., New Jersey.
40. Brailsford T.J. și Faff R. W. (1995) An evaluation of volatility forecasting techniques, *Journal of Banking and Finance*, Vol. 20, pg. 419-38.
41. Breidt F. J., Crato N. și de Lima P. J. F. (1997) Modeling the Persistent Volatility of Asset Returns, *Proceedings of the IEEE/IAFE Conference on Computational Intelligence for Financial Engineering (CIFEr)*, Piscataway, NJ, pg. 266-272

42. Brock P. (1992) *If Texas Were Chile—A Primer on Banking Reform*, San Francisco: ICS.
43. Brooks R. D., Faff R. W, McKenzie M. D. și Mitchell H. (2000), A multi-country study of power ARCH models and national stock market returns, *Journal of International Money and Finance*, Vol. 19(3), pg. 377-397.
44. Brooks C. și Persaud A. G. (2003) Volatility forecasting for risk management, *Journal of Forecasting*, Vol. 22, pg. 1-22.
45. Bryant J. (1980), A Model of Reserves, Bank Runs, and Deposit Insurance, *Journal of Banking and Finance*, Vol. 4(4), pg. 335-344.
46. Burns P. (2005) Multivariate GARCH with only univariate estimation, retrieved June 20th, from Burns Statistics <http://www.burns-stat.com/>.
47. Calomiris C. (1999) Runs on Banks and Lessons of the Great Depression, *Regulation* 22, Nr. 1: 4–7.
48. Calomiris C. și Gorton G. (1991) *The Origins of Banking Panics: Models, Facts, and Bank Regulation*. In *Financial Markets and Financial Crises*, edited by R. Glenn Hubbard, pg. 109–173, Chicago: University of Chicago Press.
49. Campbell J. Y., Lo A. W. și MacKinlay A. C. (1997) *The Econometrics of Financial Markets*, Princeton University Press, Princeton, N. J.
50. Chaudhury M. și Wei J. Z. (1996) A comparative Study of GARCH(1,1) and Black-Scholes Option Prices, *McGill Finance Centre Working Paper*, www.mfrc.mcgill.ca.
51. Chorafas Dimitris (2000) *Managing Credit Risk*. London: Euromoney Institutional Investor PLC
52. Christoffersen P. F. și Diebold X. F. (2000) Volatility forecastability in risk management, *The Review of Economics of Economics and Statistics*, Vol. 82, Ediția 1, pg. 12-22.

53. Corrigan G. (1987) Financial Market Structure: A Longer View, *Annual Report*, Federal Reserve Bank of New York, pg. 3–54, New York: Federal Reserve Bank of New York.
54. Cottrel A., Lawlor M. și Wood J. (1995) *What are the connections between deposit insurance and bank failures?* In *The Causes and Costs of Depository Institution Failures*, edited by Allin Cottrell, Michael Lawlor, and John Wood, pg. 163–197, Norwell, Mass.: Kluwer.
55. Crockett A. (1997), Why Is Financial Stability a Goal of Public Policy?, *Maintaining Financial Stability in a Global Economy*, 7–36. Kansas City, Mo.: Federal Reserve Bank of Kansas City.
56. Crockett A. (2000) *Marrying the Micro- and Macro-Prudential Dimensions of Financial Stability*, Basel, Switzerland: Bank for International Settlements.
57. Cumby R., Figlewski S. și Hasbrouck J. (1993), Forecasting volatility and correlations with EGARCH models, *Journal of Derivatives*, Vol. 1, No. Winter, pg. 51-63.
58. Davis P. (1995) *Debt, Financial Fragility, and Systemic Risk*, Oxford: Oxford University Press.
59. de Jong F., Kemna A. și Kloek T. (1992) A contribution to event study methodology with an application to the Dutch stock market, *Journal of Banking and Finance*, vol. 16, pg. 11-36.
60. Dermine J. (1996) *Comment on the paper by Niklaus Blattner "Capital Adequacy Regulation*, *Swiss Journal of Economics and Statistics*, Vol 132(IV), pp.: 679–682.
61. Diamond D. și Dybvig P. (1983) Bank runs, deposit insurance, and liquidity, *Journal of Political Economy*, Vol. 91 (3), pg. 401–419.

62. Diebold F. X. și Lopez J. A. (1996) Forecast Evaluation and Combination, *Handbook of Statistics*, Vol 14, G.S. Maddala and C.R. Rao (eds.), Elsevier Science B.V., North-Holland, pg. 241-268.
63. Diebold F. X. și Mariano R. S. (1995) Comparing predictive accuracy, *Journal of Business and Economic Statistics*, Vol. 13, pg. 253-265.
64. Dimson E. și Marsh P. (1990) Volatility forecasting without data snooping, *Journal of Banking and Finance*, Vol. 14, pg. 399-21.
65. Dobrescu E. (2006) Integration of macroeconomic behavioural relationships and the input-output block (Romanian modeling experience), Paper presented at the *International Conference on Policy Modeling (Ecomod 2006)*, Hong Kong, June 28-30, 2006, <http://www.ecomod.org/files/papers/1564.pdf>.
66. Dobrescu Emilian (2006) *Macromodels of the Romanian Market Economy*, Editura Economica: Bucharest.
67. Dosescu T. și Raischi C. (2008) The econometric model of a random system that generates time series data, *Economic Computation and Economics Cybernetics Studies and Research*, Vol. 42, Ediția 3-4, pg. 85-97.
68. Dospinescu A. S. (2005) Combining the forecasts using a statistical approach, *Romanian Journal for Economic Forecasting*, Vol. 6, Ediția 2, pg. 72-84.
69. Drost F. C. și Nijman T. E. (1993) Temporal Aggregation of GARCH Processes, *Econometrica*, Vol. 61(4), pg. 909-927.
70. Duffie D. și Huang M. (1996) Swap rates and credit quality, *Journal of Finance*, Vol. 51, pg. 921-949.
71. Duffy J. și Unver M. U. (2006) Asset price bubbles and crashes with near-zero-intelligence traders, *Economic Theory*, Vol. 27, pg. 537-563.

72. Eisenbeis R. (1995) Private sector solutions to payments system fragility, *Journal of Financial Services Research*, Vol. 9, pg. 327–350.
73. Eisenberg L. și Noe T. (2001) Systemic risk in financial systems, *Management Science*, Vol. 47, pg. 236-249.
74. Elimam A., Girgis M. și Kotob S. (1997) A solution to post crash debt entanglements in Kuwait's al Manakh Stock Market, *Interfaces* Vol. 27(1), pg. 89-106.
75. Ely B. (1993) *Savings and Loan Crisis*. In *The Fortune Encyclopedia of Economics*, edited by David R. Henderson, pg. 369–75, New York: Warner.
76. Enders W. (2004) *Applied Econometric Time Series*, N.J: John Wiley & Sons, Hoboken.
77. Engle R. F. (1995, repr. 2000) *ARCH : selected readings*, Oxford : Oxford University Press.
78. Engle R. F. (1982) Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation, *Econometrica*, 50:4, pg. 987-1007.
79. Engle R. F. (1993), Statistical Models for Financial Volatility, *Financial Analysts Journal*, Vol. 49(1), pg. 72-78.
80. Engle R. F. (2001) GARCH 101: The use of ARCH/GARCH models in applied Econometrics, *Journal of Economic Perspectives*, Vol. 15, Nr. 4, pg. 157-68.
81. Engle R. F. și Bollerslev T. (1986) Modeling the persistence of conditional variances, *Econometric Reviews*, Vol. 5(1), pg. 1-50
82. Engle R. și Ng V. K. (1993) Measuring and Testing the Impact of News on Volatility, *The Journal of Finance*, Vol. XLVIII, Nr. 5.
83. Engle R. F. și Patton A. J. (2001) What good is a volatility model? *Quantitative Finance*, Vol 1, pg. 237-45.

84. Engle R. F. și White H. (1999) *Cointegration, causality, and forecasting*, Oxford : Oxford University Press.
85. Federal Deposit Insurance Corporation (FDIC) (1998) *Managing the Crisis: The FDIC and RTC Experience, 1980–1990*, Washington, D.C.: FDIC.
86. Federal Reserve Board (2000) *Fedwire Statistics: Annual Volume and Value*. Retrieved at: <http://www.Federalreserve.gov/PaymentSystems/FedWire>.
87. Figlewski S. (2004) Forecasting Volatility, Working Paper, NYU Stern School of Business, Retrieved at <http://pages.stern.nyu.edu/~sfiglews/Docs/Forecasting%20Volatility.pdf>
88. Franses P. H. și Van Dijk D. (1996), Forecasting Stock Market Volatility Using (Non-Linear) GARCH Models, *Journal of Forecasting*, Vol. 15, pg. 229-235.
89. French K. R., Schwert G. W. și Stambaugh R. F. (1987) Expected Stock Returns and Volatility, *Journal of Financial Economics*, Vol. 19(1), pg. 3-29.
90. Furfine C. (2003) Interbank Exposures: Quantifying the Risk of Contagion, *Journal of Money, Credit, and Banking*, Vol. 35(1), pg. 111-128.
91. George E. A. J. (1998) *The New Lady of Threadneedle Street. Governor's Speech*, London: Bank of England.
92. Glosten L. R., Jagannathan R. și Runkle D. E. (1993) On the relation between the expected value and the volatility of the nominal excess return on stocks, *Journal of Finance*, Vol. 48(5), pg. 1779-1801.
93. Gouriéroux C. și Jasiak J. (2002) Nonlinear autocorrelograms with application to intertrade durations, *Journal of Time Series Analysis*, Vol. 23, pg. 127-154.
94. Hamilton J. D. (1994) *Time Series Analysis*, Princeton: Princeton University Press.

95. Hancock D., Wilcox J. și Humphrey D (1996) Intraday management of bank reserves, *Journal of Money, Credit, and Banking*, Vol. 28(4), pg. 870-908.
96. Hansen P. R. (2001) An unbiased and powerful test for superior predictive ability, *Working Papers 2001-2006*, Brown University, Department of Economics.
97. Hansen P. R. și Lunde A. (2001) A comparison of volatility models: does anything beat a GARCH(1,1)?, *Working Paper Series Nr. 84*, Aarhus School of Business, Centre for Analytical Finance, pg. 1-41.
98. Hansen P. R. și Lunde A. (2003) Does anything Beat a GARCH(1,1)? A Comparison Based on Test for Superior Predictive Ability, *Proceedings for The 2003 IEEE International Conference on Computational Intelligence for Financial Engineering*, pg. 301-307.
99. Hansson B. și Hördahl P. (2005) Forecasting Variance Using Stochastic Volatility and GARCH, *The European Journal of Finance*, Vol. 11(1), pg. 33-57.
100. Hartia S. și Scutaru C. (1987) Model for simulating the economic efficiency of land improvement work, *Economic Computation and Economic Cybernetics Studies and Research*, Vol. 22(1), pg. 57-59.
101. Harvey A. C., Ruiz E. și Shephard N. (1994) Multivariate stochastic variance models, *Review of Economic Studies*, Vol. 61, Ediția 2, pg. 247-64.
102. Hellwig M. (1994) Liquidity Provision, Banking, and the Allocation of Interest Rate Risk, *European Economic Review*, Vol. 38, pg. 1363-1389.
103. Hendershott P. H. (2000) Property asset bubbles: evidence from the Sydney office market, *Journal of Real Estate Finance and Economics*, Vol. 20(1), pg. 67-81.
104. Herring R. și Wachter S. (1999) Real Estate Booms and Banking Busts—An International Perspective, *Occasional Paper no. 58*, Washington, D.C.: Group of Thirty. Paper presented at the Wharton Conference on Asian Twin Financial Crisis, March, Long Term Credit Bank, Tokyo.

105. Hol. E. și Koopman S. J. (2002) Forecasting the Variability of Stock Index Returnswith Stochastic Volatility Models and Implied Volatility, *Tinbergen Institute Discussion Papers*, Nr. 00-104/4, pg. 1-23.
106. Jacquier E., Polson N. G. și Rossi P. E. (1994) Bayesian Analysis of Stochastic Volatility Models, *Journal of Business and Economic Statistics*, Vol. 12(4), pg. 371-89.
107. Jones D. și King K. (1995), The implementation of prompt corrective action: an assessment, *Journal of Banking and Finance*, Vol. 19(3-4), pg. 491–510.
108. Jordan J., Peek J. și Rosengren E. (2000) The Market Reaction to the Disclosure of Supervisory Actions: Implications for Bank Transparency, *Journal of Financial Intermediation*, Vol. 9(3), pg. 298–319.
109. Jorion P. (1995), Predicting volatility in the foreign exchange market, *Journal of Finance*, Vol. 50(2), pp.507-528.
110. Jorion P. (1996), *Risk and turnover in the foreign exchange market*, in Franke, J.A., Galli, G., Giovannini, A. (Eds), *The Microstructure of Foreign Exchange Markets*, Chicago, IL.: Chicago University Press.
111. Kaminsky G. și Reinhart C. (1998) On Crises, Contagion, and Confusion. *Working Paper*, December. Washington, D.C.: George Washington University.
112. Kane E. J. (1980) *Regulation, savings and loan diversification, and the flow of housing finance*. In *Savings and Loan Asset Management under Deregulation*, pg. 81–109, San Francisco: Federal Home Loan Bank of San Francisco, December.
113. Kaufman G. G. (1994) Bank Contagion: A Review of the Theory and Evidence, *Journal of Financial Services Research*, Vol. 8, pg. 123–50.
114. Kaufman G G. (1995a) *Comment on Systemic Risk*. In *Research in Financial Services: Banking, Financial Markets, and Systemic Risk*, vol. 7, edited by George G. Kaufman, pg. 47–52, Greenwich, Conn.: JAI.

115. Kaufman, G. G. (1995b) The U.S. banking debacle of the 1990s: overview and lessons, *Financier*, Vol. 2, pg. 9–26.
116. Kaufman G. G. (1996) Bank Failures, Systemic Risk, and Bank Regulation. *Cato Journal*, Vol. 16(1), pg. 17–45.
117. Kaufman G. G. (1999) *Central banks, asset bubbles, and financial stability*. In *Central Banks, Monetary Policies, and the Implications for Transition Economies*, edited by Mario Blejer and Marko Skreb, pg. 143–183, Boston: Kluwer.
118. Kaufman G. G. (2000a) Banking and currency crises and systemic risk: a taxonomy and review, *Financial Markets, Institutions, and Instruments*, Vol. 9, pg. 69–131.
119. Kaufman G. G. și Steven Seelig (2002) Post-resolution treatment of depositors at failed banks and the severity of bank crises, systemic risk, and too-big-to-fail, *Economic Perspectives*, Federal Reserve Bank of Chicago, pg. 27–41.
120. Khalid A. M. și Rajaguru G. (2006) Financial Market Contagion or Spillovers. Evidence from Asian Crisis Using Multivariate GARCH Approach, Bond University, Australia.
121. Klaasen F. (2002) Improving GARCH volatility forecasts, *Empirical Economics*, Vol. 27, pg. 363-394.
122. Klein A. (2004) Credit raters exert international influence, *The Washington Post*. Retrieved on October 23rd 2008 at: <http://www.washingtonpost.com/ac2/wp-dyn/A5572-2004Nov22?language=printer>
123. Koopman S. J., Jungbacker B. și Hol E. (2004) Forecasting daily variability of the S&P 100 stock index using historical, realised and implied volatility measurements, *Tinbergen Institute Discussion Papers*, 04-016/4.
124. Kumar S.S.S (2006) Comparative performance of volatility forecasting models in Indian markets, *Decision*, Vol. 33, Vol. 2, pg. 26-40.

125. Lamark B., Siegert P. J. și Walle J. (2005) Volatility modeling: from ARMA to ARCH, *Global Finance*, Vol. 15, Nr. 2, pg. 83-101.
126. Liu H.-C., Lee Y.-H. și M.C. Lee (2009) Forecasting China stock Markets Volatility via GARCH Models Under Skewed-GED Distribution, *Journal of Money, Investment and Banking*, Ediția 7, pg. 5-15.
127. Lupu R. (2006) Using BDS to check the forecasting power of the stochastic volatility model, *Economic Computation and Economics Cybernetics Studies and Research*, Vol. 2006 (1-2), pg. 223-.
128. Mapa D. S. (2004) A forecast comparison of financial volatility models: GARCH (1,1) is not enough, *The Philippine Statistician*, Vol. 53, pg. 1-10.
129. Marcucci J. (2005) Forecasting stock market volatility with regime-switching GARCH models, *Studies in Nonlinear Dynamics & Econometrics*, Vol. 9(4), Article 6.
130. Marin D. și Ruxanda G. (2006) Selections modeling under conditions of risk and uncertainty, Vol. 2006 (1-2).
131. Martens M. (2001) Forecasting daily exchange rate volatility using intraday returns, *Journal of International Money and Finance*, Vol. 20(1), pg. 1-23.
132. Matei M. și Cabat D. (2003) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 10 (Ian.), pg. 29-33, Milano: UniCredito Italiano.
133. Matei M. și Cabat D. (2003) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 11 (Apr.), pg. 26-30, Milano: UniCredito Italiano.
134. Matei M. și Cabat D. (2003) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 12 (Iul.), pg. 31-35, Milano: UniCredito Italiano.

135. Matei M. (2003) Romania section, *New Europe Quarterly Macroeconomic Update – special issue 2004 scenario*, Ediția 13 (Oct.), pg. 87-100, Milano: UniCredito Italiano.
136. Matei M. (2004) Romania section, *New Europe Quarterly Macroeconomic Update*, Ediția 14 (Ian.), pg. 51-57, Milano: UniCredit Group.
137. Matei M. (2004) Romania section, *New Europe Quarterly Macroeconomic Update*, Ediția 15 (Mai), pg. 39-44, Milano: UniCredit Group.
138. Matei M. et al. (2004) *Household Wealth in New Europe: Towards the EU*, Ediția Iulie, pg. 1-36, Milano: UniCredit Group.
139. Matei M. (2004) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 16 (Iul.), pg. 37-42, Milano: UniCredit Group.
140. Matei M. (2004) Romania Section, *New Europe Quarterly Macroeconomic Update – special Ediția 2005 scenario*, Ediția 17 (Oct.), Milano: UniCredit Group.
141. Matei M. et al. (2004) *New Europe Focus: Impact of an oil shock in the New Europe*, Ediția Decembrie, pg. 1-8, Milano: UniCredit Group.
142. Matei M. et al. (2004) *New Europe Focus: Economic cycle in the New Europe: converging towards the EMU*, Ediția Decembrie, pg. 1-8, Milano: UniCredit Group.
143. Matei M. (2005) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 18 (Feb.), pg. 45-50, Milano: UniCredit Group.
144. Matei M. și Popescu M. C. (2005) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 19 (Mai), pg. 45-50, Milano: UniCredit Group.
145. Matei M. et al. (2005) *New Europe Focus: Exchange Rates Dynamics towards the Euro*, Ediția Aprilie, pg. 1-18, Milano: UniCredit Group.

146. Matei M. și Popescu M. C. (2005) Romania Section, *New Europe Quarterly Macroeconomic Update*, Ediția 20 (Iul.), pg. 45-50, Milano: UniCredit Group.
147. Matei M. et al. (2002 - 2005), *New Europe Biweekly Monitor*, pg. 1- 30, Milano: UniCredit Group.
148. Matei M. (2009) Assessing volatility forecasting models: why GARCH models take the lead, *Romanian Journal for Economic Forecasting*, Bucharest: Institute for Economic Forecasting, Romanian Academy.
149. McAndrews J. și Rajan S. (2000), The timing and funding of Fedwire funds transfers, *Economic Policy Review*, Federal Reserve Bank of New York, Vol. 6(2), pg. 17-32.
150. McMillan D. și Speight A. E. H. (2004) Daily Volatility Forecasts: Reassessing the Performance of GARCH Models, *Journal of Forecasting*, Vol. 23, pg. 449-460.
151. McMillan D., Speight A. E. H. și Gwilym O. (2000), Forecasting UK stock market volatility, *Applied Financial Economics*, Vol. 10, pg. 435-448.
152. Melino A. și Turnbull S.M. (1990) Pricing foreign currency options with stochastic volatility, *Journal of Econometrics*, Vol. 45, pg. 239-265.
153. Mishkin F. (1991) *Asymmetric information and financial crises: a historical perspective*. In *Financial Markets and Financial Crises*, edited by R. Glenn Hubbard, pg. 69–108, Chicago: University of Chicago Press.
154. Mishkin F. (1995) *Comment on systemic risk*. In *Research in Financial Services: Banking, Financial Markets, and Systemic Risk*, Vol. 7, edited by George Kaufman, pg. 31–45, Greenwich, Conn.: JAI.
155. Moody's Investors Service (1991, Reprinted 1995) *Global Credit Analysis*. London: IFR Publishing Ltd.

156. Nastac I., Dobrescu E. și Pelinescu E. (2007) Neuro-adaptive model for financial forecasting, *Romanian Journal for Economic Forecasting*, Vol. 8, Ediția 3, pg. 19-41.
157. Nelson D. B. (1991) Conditional heteroskedasticity in asset returns: A new approach, *Econometrica*, Vol. 59, pg. 347-370.
158. Nicholls D. F. și Quinn B. G. (1982) *Random Coefficient Autoregressive Model: An introduction*, New York, Springer-Verlag.
159. O'Connor J. F. T. (1938) *The Banking Crisis and Recovery under the Roosevelt Administration*. Chicago: Callaghan and Co.
160. Pafka S. și Kondor I. (2001) Evaluating the RiskMetrics methodology in measuring volatility and Value-at-Risk in financial markets, retrieved July 25th, at <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.27.4459>.
161. Pagan A. R. și Schwert G. W. (1989) Alternative models for conditional stock volatility, NBER Working Paper Series, Nr. 2955
162. Pederzoli C. (2006) Stochastic volatility and GARCH: a comparison based on UK stock data, *The European Journal of Finance*, Vol. 12, Nr. 1, pg. 41-59.
163. Peltzman S. (1970) Capital investment in commercial banking, *Journal of Political Economy*, Vol. 78, pg. 1-26.
164. Pierre E. F. (1998) Estimating EGARCH-M models: science or art?, *The Quarterly Review of Economics and Finance*, Vol. 38(2), pg. 167-180.
165. Polasek W. și Ren L. (2001) Volatility analysis during the Asia crisis: a multivariate GARCH-M model for stock returns in the US, Germany and Japan, *Applied Stochastic Models in Business and Industry*, Vol. 17(1), pg. 93-108.
166. Poon S. H. și Granger C. (2001) Forecasting Volatility in Financial Markets: A Review, *Journal of Economic Literature*, Vol XLI, pg. 478-539.

167. Poon S. H. și Taylor S. J. (1992) Stock returns and volatility: An empirical study of the UK stock market, *Journal of Banking and Finance*, Vol. 16, pg. 37-59.
168. Raimbourg P. (1990) *Les Agences de Rating*, Paris: Economica.
169. Rochet J.-C. și Tirole J. (1996) Interbank lending and systemic risk, *Journal of Money Credit and Banking*, Vol. 28, pg. 733-762.
170. Santos M. și Woodford M. (1997) Rational asset pricing bubbles, *Econometrica*, Vol. 65(1), pp.19-57.
171. Schwert G. W. (1990) Stock market volatility, *Financial Analysts Journal*, Vol. 46, pg. 23-34.
172. Schwert G. W. (1990) Stock volatility and the crash of '87, *The Review of Financial Studies*, Vol. 3(1), pg. 77-102.
173. Schwert G. W. (1997) Stock market volatility: ten years after the crash, *NBER Working Paper*, Nr. 6381.
174. Schwert G. W. și Seguin P. J. (1990) Heteroskedasticity in stock returns, *The Journal of Finance*, Vol. XLV(4), pg. 1129-1155.
175. Scott K. și Mayer T. (1971) Risk and regulation in banking: some proposals for Federal Deposit Insurance reform, *Stanford Law Review*, Vol. 23, pg. 857–916.
176. Scutaru C., Saman C. și Stanica C. (2008) Predictability and complexity in Macroeconomics. The case of gross fixed capital formation in the Romanian economy, *Romanian Journal for Economic Forecasting*, Vol. 9, Ediția 4, pg. 196-205
177. Sheldon G. și Maurer M. (1998) Interbank lending and systemic risk: an empirical analysis for Switzerland, *Swiss Journal of Economics and Statistics*, Vol. 134, pg. 685–704.

178. Silvennoinen A. și Teräsvirta (2008) Multivariate GARCH models, *CREATES (Center for research in Econometric Analysis of Time Series) Research Paper*, Nr. 6. To appear in T. G. Andersen, R. A. Davis, J.-P. Kreiss and T. Mikosch, eds. *Handbook of Financial Time Series*, New York: Springer.

179. Smith L. I. (2002) A tutorial on Principal Component Analysis, retrieved on March 15th, at http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf

180. Taylor S. J. (1994) Modeling stochastic volatility: a review and comparative study, *Mathematical Finance*, Vol. 4, Ediția 2, pg. 183-04.

181. The Technical Committee of the International Organization of Securities Commissions (IOSCO) (2003) Report on the Activities of Credit Rating Agencies. Retrieved on October 20th 2008 at: <http://www.iosco.org/library/pubdocs/pdf/IOSCOPD153.pdf>

182. The Technical Committee of the International Organization of Securities Commissions (IOSCO) (2003) IOSCO Statement of Principles Regarding the Activities of Credit Rating Agencies. Retrieved on October 20th 2008 at: <http://www.iosco.org/library/pubdocs/pdf/IOSCOPD151.pdf>

183. Tsay R. S. (1987) Conditional heteroskedastic time series models, *Journal of American Statistical Association*, Vol. 82, pg. 590-604.

184. Tsay R. S. (2005) *Analysis of financial time series*, 2nd edition, New Jersey: Wiley Series in Probability and Statistics.


185. Tse Y. K. (1991) Stock return volatility in the Tokyo stock exchange, *Japan and the World Economy*, Vol. 3, pg. 285-298.

186. Tse Y. K. și Tung S. H. (1992) Forecasting volatility in the Singapore stock market, *Asia Pacific Journal of Management*, Vol. 9(1), pp.1-13.


187. U.S. Shadow Financial Regulatory Committee (2001) The Basel Committee's Revised Capital Accord Proposal, *Policy statement No. 169*, Washington, D.C.
188. Van der Weide R. (2002) GO-GARCH: A multivariate generalized Orthogonal GARCH model, *Journal of Applied Econometrics*, Vol. 17, pg. 549-64.
189. Von Thadden E.-L. (1998) Intermediated versus direct investment: optimal liquidity provision and dynamic incentive compatibility, *Journal of Financial Intermediation*, Vol. 7 (2), pg. 177-197.
190. West K. D. și Cho D. (1995) The predictive ability of several models of exchange rate volatility, *Journal of Econometrics*, Vol. 69(2), pg. 367-391.
191. White H. (2000) A reality check for data snooping, *Econometrica*, Econometric Society, Vol. 68(5), pg. 1097-1126.
192. Whitehouse M. (1999) Frustration soars for Russian bank depositors, *Wall Street Journal*, April 8.
193. Wicker E. (1996) *The Banking Panics of the Great Depression*, Cambridge, England: Cambridge University Press.
194. Zakoian J.-M. (1994) Threshold heteroskedasticity models, *Journal of Economic Dynamics and Control*, Vol. 15, pg. 931-955.
195. Zhou R. (2000) Understanding intraday credit in large-value payment systems, *Economic Perspectives*, Federal Reserve Bank of Chicago, XXIV, pg. 29-44.

E. Anexo


Anexa 1




Anexa 2



Anexa 3



Anexa 4



Anexa 5

H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value
1.00	0.0080	7.0399	3.8415	0.00	0.3379	0.9185	3.8415	0.00	0.7643	0.0899	3.8415	1.00	0.0271	4.8841	3.8415
1.00	0.0202	7.8002	5.9915	0.00	0.1823	3.4042	5.9915	1.00	0.0002	16.6040	5.9915	1.00	0.0013	13.2495	5.9915
1.00	0.0463	7.9845	7.8147	0.00	0.2885	3.7608	7.8147	1.00	0.0006	17.4493	7.8147	1.00	0.0009	16.4375	7.8147
0.00	0.0872	8.1224	9.4877	1.00	0.0262	11.0349	9.4877	1.00	0.0015	17.5327	9.4877	1.00	0.0025	16.4523	9.4877
1.00	0.0372	11.8264	11.0705	1.00	0.0374	11.8181	11.0705	1.00	0.0020	18.9027	11.0705	1.00	0.0021	18.7746	11.0705
1.00	0.0449	12.8862	12.5916	0.00	0.0655	11.8470	12.5916	1.00	0.0037	19.2981	12.5916	1.00	0.0018	21.0042	12.5916
0.00	0.0629	13.4028	14.0671	0.00	0.0979	12.0833	14.0671	1.00	0.0068	19.4702	14.0671	1.00	0.0036	21.1083	14.0671

H	P-Value	Statistic	Critical value
0.00	0.2815	1.1600	3.8415
1.00	0.0039	11.0805	5.9915
1.00	0.0044	13.1013	7.8147
1.00	0.0085	13.6439	9.4877
1.00	0.0155	14.0123	11.0705
1.00	0.0261	14.3331	12.5916
1.00	0.0453	14.3491	14.0671

H	P-Value	Statistic	Critical value
0.00	0.1308	2.2828	3.8415
1.00	0.0322	6.8701	5.9915
0.00	0.0507	7.7848	7.8147
1.00	0.0058	14.5136	9.4877
1.00	0.0113	14.7810	11.0705
1.00	0.0212	14.8863	12.5916
1.00	0.0106	18.3141	14.0671

H	P-Value	Statistic	Critical value
0.00	0.0657	3.3867	3.8415
1.00	0.0000	25.4908	5.9915
1.00	0.0000	25.6939	7.8147
1.00	0.0000	26.1081	9.4877
1.00	0.0000	28.0351	11.0705
1.00	0.0000	29.9922	12.5916
1.00	0.0000	35.0698	14.0671

Anexa 6

H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value
1.00	0.0000	55.7352	3.8415	1.00	0.0001	14.986	3.8415	1.00	0.0000	68.5135	3.8415	1.00	0.0000	61.7306	3.8415
1.00	0.0000	71.1167	5.9915	1.00	0.0000	26.6524	5.9915	1.00	0.0000	78.3246	5.9915	1.00	0.0000	102.7452	5.9915
1.00	0.0000	79.9231	7.8147	1.00	0.0000	29.7582	7.8147	1.00	0.0000	98.387	7.8147	1.00	0.0000	133.2275	7.8147
1.00	0.0000	86.2279	9.4877	1.00	0.0000	32.4745	9.4877	1.00	0.0000	108.127	9.4877	1.00	0.0000	157.9182	9.4877
1.00	0.0000	93.5747	11.0705	1.00	0.0000	34.5962	11.0705	1.00	0.0000	111.4049	11.0705	1.00	0.0000	188.265	11.0705
1.00	0.0000	111.3294	12.5916	1.00	0.0000	35.6367	12.5916	1.00	0.0000	115.573	12.5916	1.00	0.0000	209.6915	12.5916
1.00	0.0000	113.2919	14.0671	1.00	0.0000	35.6941	14.0671	1.00	0.0000	115.6258	14.0671	1.00	0.0000	224.6931	14.0671

H	P-Value	Statistic	Critical value
1.00	0.0000	68.6695	3.8415
1.00	0.0000	88.7138	5.9915
1.00	0.0000	107.6164	7.8147
1.00	0.0000	134.4484	9.4877
1.00	0.0000	139.7539	11.0705
1.00	0.0000	158.5228	12.5916
1.00	0.0000	162.9093	14.0671

H	P-Value	Statistic	Critical value
1.00	0.0000	78.7403	3.8415
1.00	0.0000	138.865	5.9915
1.00	0.0000	175.4097	7.8147
1.00	0.0000	192.7023	9.4877
1.00	0.0000	197.9961	11.0705
1.00	0.0000	217.1309	12.5916
1.00	0.0000	225.6581	14.0671

H	P-Value	Statistic	Critical value
1.00	0.0000	65.8503	3.8415
1.00	0.0000	162.344	5.9915
1.00	0.0000	222.2332	7.8147
1.00	0.0000	236.2768	9.4877
1.00	0.0000	245.5152	11.0705
1.00	0.0000	316.0154	12.5916
1.00	0.0000	328.3765	14.0671

Anexa 7

	Value	T-stat
C	12.06×10^{-4}	3.21
α_0	3.06×10^{-6}	6.06
α_1	9.71×10^{-1}	524.93
β_1	2.75×10^{-2}	15.42

	Value	T-stat
C	18.09×10^{-4}	4.55
α_0	52.95×10^{-6}	10.21
α_1	8.68×10^{-1}	111.68
β_1	8.38×10^{-2}	24.92

	Value	T-stat
C	14.51×10^{-4}	3.81
α_0	62.19×10^{-6}	11.67
α_1	8.38×10^{-1}	78.92
β_1	10.24×10^{-2}	15.68








	Value	T-stat
C	19.30×10^{-4}	6.26
α_0	9.17×10^{-6}	8.07
α_1	9.20×10^{-1}	162.85
β_1	7.13×10^{-2}	14.01

	Value	T-stat
C	11.32×10^{-4}	3.30
α_0	3.59×10^{-6}	8.74
α_1	9.50×10^{-1}	352.34
β_1	4.81×10^{-2}	18.14


	Value	T-stat
C	10.01×10^{-4}	4.13
α_0	6.41×10^{-6}	13.02
α_1	9.20×10^{-1}	204.17
β_1	6.94×10^{-2}	18.24

	Value	T-stat
C	3.89×10^{-4}	2.05
α_0	2.66×10^{-6}	8.75
α_1	9.57×10^{-1}	288.22
β_1	3.08×10^{-2}	13.84


Anexa 8



Anexa 9



Anexa 10



Anexa 11

H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value
0.00	0.2463	1.3444	3.8415	0.00	0.8357	0.0430	3.8415	0.00	0.6470	0.2097	3.8415	0.00	0.4262	0.6333	3.8415
0.00	0.3593	2.0470	5.9915	0.00	0.9582	0.0853	5.9915	0.00	0.5927	1.0462	5.9915	0.00	0.7251	0.6428	5.9915
0.00	0.5552	2.0838	7.8147	0.00	0.9497	0.3531	7.8147	0.00	0.6835	1.4947	7.8147	0.00	0.8825	0.6602	7.8147
0.00	0.7135	2.1209	9.4877	0.00	0.8994	1.0674	9.4877	0.00	0.7951	1.6756	9.4877	0.00	0.9363	0.8159	9.4877
0.00	0.8234	2.1821	11.0705	0.00	0.9569	1.0679	11.0705	0.00	0.5298	4.1372	11.0705	0.00	0.7428	2.7220	11.0705
0.00	0.8985	2.2191	12.5916	0.00	0.9795	1.1457	12.5916	0.00	0.5982	4.5838	12.5916	0.00	0.8078	3.0083	12.5916
0.00	0.9147	2.6583	14.0671	0.00	0.9243	2.5368	14.0671	0.00	0.2536	8.9875	14.0671	0.00	0.7963	3.8556	14.0671

H	P-Value	Statistic	Critical value
0.00	0.1222	2.3895	3.8415
0.00	0.2146	3.0775	5.9915
0.00	0.3165	3.5332	7.8147
0.00	0.4728	3.5332	9.4877
0.00	0.4202	4.9645	11.0705
0.00	0.5327	5.0870	12.5916
0.00	0.6457	5.1170	14.0671

H	P-Value	Statistic	Critical value
0.00	0.7455	0.1054	3.8415
0.00	0.9365	0.1312	5.9915
0.00	0.9380	0.4110	7.8147
0.00	0.9811	0.4169	9.4877
0.00	0.9947	0.4230	11.0705
0.00	0.9872	0.9572	12.5916
0.00	0.9954	0.9614	14.0671

H	P-Value	Statistic	Critical value
0.00	0.0695	3.2956	3.8415
0.00	0.1686	3.5610	5.9915
0.00	0.2954	3.7027	7.8147
0.00	0.3568	4.3821	9.4877
0.00	0.3618	5.4653	11.0705
0.00	0.2689	7.5997	12.5916
0.00	0.3645	7.6497	14.0671

Anexa 12

H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value	H	P-Value	Statistic	Critical value
0.00	0.9058	0.0140	3.8415	0.00	0.9346	0.0067	3.8415	0.00	0.7696	0.0858	3.8415	0.00	0.9148	0.0114	3.8415
0.00	0.9871	0.0259	5.9915	0.00	0.9965	0.0070	5.9915	0.00	0.9014	0.2076	5.9915	0.00	0.9728	0.0551	5.9915
0.00	0.9978	0.0407	7.8147	0.00	0.9995	0.0146	7.8147	0.00	0.9498	0.3530	7.8147	0.00	0.9926	0.0934	7.8147
0.00	0.9997	0.0524	9.4877	0.00	0.9999	0.0338	9.4877	0.00	0.9755	0.4793	9.4877	0.00	0.9978	0.1342	9.4877
0.00	0.9999	0.0699	11.0705	0.00	1.0000	0.0415	11.0705	0.00	0.9835	0.6895	11.0705	0.00	0.9992	0.1954	11.0705
0.00	1.0000	0.0891	12.5916	0.00	1.0000	0.0526	12.5916	0.00	0.9937	0.7365	12.5916	0.00	0.9996	0.2684	12.5916
0.00	1.0000	0.1095	14.0671	0.00	1.0000	0.0759	14.0671	0.00	0.9952	0.9742	14.0671	0.00	0.9998	0.3512	14.0671

H	P-Value	Statistic	Critical value
0.00	0.9699	0.0014	3.8415
0.00	0.9977	0.0046	5.9915
0.00	0.9920	0.0986	7.8147
0.00	0.9970	0.1580	9.4877
0.00	0.9973	0.3200	11.0705
0.00	0.9988	0.4073	12.5916
0.00	0.9996	0.4368	14.0671

H	P-Value	Statistic	Critical value
0.00	0.9170	0.0109	3.8415
0.00	0.9896	0.0210	5.9915
0.00	0.9992	0.0212	7.8147
0.00	0.9999	0.0303	9.4877
0.00	1.0000	0.0371	11.0705
0.00	1.0000	0.0483	12.5916
0.00	1.0000	0.0568	14.0671

H	P-Value	Statistic	Critical value
0.00	0.8679	0.0277	3.8415
0.00	0.9705	0.06	5.9915
0.00	0.9945	0.0765	7.8147
0.00	0.9976	0.1415	9.4877
0.00	0.9989	0.2174	11.0705
0.00	0.9998	0.2242	12.5916
0.00	0.9999	0.2974	14.0671

Anexa 13a

	P1	P2	P3	P4	P5	P6	P7
ADOBE	0.3793	-0.0414	0.3343	-0.4477	0.6597	0.3140	0.0919
APPLE	0.3639	0.2571	-0.3263	-0.6960	-0.3840	-0.2503	0.0226
AUTODESK	0.3448	-0.0754	0.7747	0.0908	-0.5140	-0.0483	0.0211
CISCO	0.4337	0.1590	-0.0809	0.2631	0.1752	-0.1738	-0.8062
DELL	0.4022	0.2411	-0.2988	0.3107	-0.2201	0.7129	0.1938
MICROSOFT	0.4201	0.0913	-0.1025	0.3753	0.2539	-0.5454	0.5495
3M	0.2804	-0.9136	-0.2742	-0.0178	-0.0977	0.0227	-0.0338

Anexa 13b

PC	Eigenvalue	% of var explained
P1	2.9902	42.71%
P2	0.8372	11.96%
P3	0.7596	10.85%
P4	0.6888	9.84%
P5	0.6651	9.50%
P6	0.5578	7.97%
P7	0.5027	7.18%

Anexa 14

	Value	T-stat		Value	T-stat		Value	T-stat		Value	T-stat
C	-24.08×10^{-3}	-1.02	C	4.91×10^{-3}	0.40	C	-13.09×10^{-3}	-1.06	C	11.17×10^{-3}	0.95
α_0	8.21×10^{-3}	2.16	α_0	4.24×10^{-1}	8.74	α_0	3.15×10^{-1}	1.51	α_0	24.53×10^{-2}	4.85
α_1	9.88×10^{-1}	364.46	α_1	4.08×10^{-1}	6.48	α_1	5.69×10^{-1}	2.03	α_1	5.99×10^{-1}	7.82
β_1	9.52×10^{-3}	5.48	β_1	8.86×10^{-2}	7.93	β_1	15.80×10^{-3}	1.73	β_1	4.63×10^{-2}	5.27

	Value	T-stat		Value	T-stat		Value	T-stat
C	12.16×10^{-3}	1.05	C	16.95×10^{-3}	1.73	C	6.79×10^{-3}	0.72
α_0	64.34×10^{-2}	3.65	α_0	9.84×10^{-2}	6.77	α_0	7.26×10^{-2}	8.56
α_1	0.00	0.00	α_1	7.55×10^{-1}	24.09	α_1	7.74×10^{-1}	34.28
β_1	3.39×10^{-2}	4.00	β_1	7.02×10^{-2}	7.90	β_1	8.61×10^{-2}	9.82

Anexa 15

