



UNIVERSITETI I MESDHETAR I SHQIPËRISË
FAKULTETI I INFORMATIKËS
DEPARTAMENTI I INFORMATIKËS SË BIZNESIT

DISERTACION

Doktoratë në Shkenca Ekonomike

**ANALIZA DHE PARASHIKIMI I SERIVE
KOHORE ME MODELE TË INTELIGJENCËS
ARTIFICIALE**

Doktorant:

MSc.Katerina Zela

Drejtues shkencor:

Prof. Asoc. Dr.Teuta Xhindi

Tiranë, 2025

DEKLARATË MBI ORIGJINALITETIN

Deklaroj se kjo tezë përfaqëson punën time origjinale dhe nuk kam përdorur burime të tjera, përveç atyre të paraqitura në Bibliografi.

Të gjitha të dhënat, tabelat, figurat dhe citimet në tekst të cilat janë riprodhuar prej ndonjë burimi tjetër, duke përfshirë edhe internetin, janë pranuar qartësisht si të tilla.

Jam e vetëdijshme se në rast të mospërputhjeve, Këshilli i Profesorëve është i ngarkuar të më revokojë gradën “Doktor”, që më është dhënë mbi bazën e kësaj teze, në përputhje me “Rregulloren e programeve të studimit të ciklit të tretë (Doktoratë) të UMSH-së.

MSc. Katerina Zela

ABSTRAKT

Parashikimi i serive kohore përfaqëson një nga sfidat më të mëdha në shkencat aplikative, ku kompleksiteti i modeleve dinamike dhe prania e strukturave të paqarta në të dhëna e bën të vështirë ndërtimin e një paradigme të vetme që ofron saktësi të lartë dhe interpretueshmëri të qartë. Në një botë gjithnjë e më të bazuar në të dhëna, ku tregjet financiare, arsimi dhe politikat publike kërkojnë vendimmarrje të bazuar në të dhëna, zhvillimi i modeleve parashikuese të sofistikuar nuk është më vetëm një nevojë akademike, por një domosdoshmëri praktike. Modelet lineare si ARIMA kanë ofruar për dekada një bazë solide për analizimin e serive kohore stacionare, ndërsa rrjetet neurale artificiale (ANN) janë shfaqur si alternativa të fuqishme për trajtimin e jolinearitetit dhe kompleksitetit të brendshëm. Megjithatë, në shumë aplikime reale, këto modele dështojnë të përballojnë të gjitha aspektet strukturore të një serie kohore në mënyrë të izoluar, duke çuar në parashikime të kufizuara ose të paqëndrueshme.

Në këtë kontekst, studimi i paraqitur ndërton dhe analizon një model hibrid ARIMA-ANN, i cili integron fuqinë e përshkrimit linear të modeleve autoregresive me aftësinë jolineare të rrjeteve NAR për të përmirësuar performancën parashikuese. Qasja metodologjike është aplikuar në katër raste praktike të lidhura ngushtë me zhvillimin ekonomik dhe social në Shqipëri: kursi i këmbimit Euro/Lek, çmimi ditor i Bitcoin-it, rezultatet e provimeve të maturës shtetërore, dhe motivimi i lektorëve në arsimin universitar teknik. Për secilin rast janë ndjekur hapat standardë të analizës së serive kohore, përfshirë testimin e stacionaritetit (përmes ADF), ndërtimin e modeleve SARIMA, ndarjen e të dhënave në trajnime dhe testime, dhe kalibrimin e rrjeteve neurale me përzgjedhje të kujdesshme të parametrave. Qëllimi është jo vetëm të realizohet parashikim sa më i mirë, por edhe të tregohet se kombinimi i njohurive statistikore klasike me inteligjencën artificiale ofron një avantazh të matshëm krahasuar me qasjet tradicionale.

Rezultatet empirike janë mbështetur nga një numër treguesish vlerësues si RMSE, MAE, MPE dhe MAPE, të cilët demonstrojnë se modeli hibrid tejkalon në mënyrë të konsiderueshme performancën e modeleve të vetme në të gjitha rastet. Për shembull, në rastin e serisë së rezultateve të maturës, gabimet relative janë ulur me mbi 90% krahasuar me modelin bazë ARIMA. Këto rezultate nuk janë vetëm statistikisht të vlefshme, por kanë edhe rëndësi praktike në përmirësimin e vendimmarrjes institucionale, menaxhimin e riskut financiar dhe përcaktimin e politikave arsimore. Në përfundim, kjo tezë kontribuon në literaturën ekzistuese duke ofruar një kornizë të qëndrueshme dhe të zgjerueshme për parashikimin e serive kohore, me aplikim konkret në kontekstin shqiptar dhe me mundësi të qarta përshtatjeje në sektorë të tjerë kritikë për zhvillimin kombëtar.

Fjalë kyçe: seri kohore, modelim, parashikim, ARIMA, ANN, modeli Hibrid ARIMA-ANN.

ABSTRACT

Time series forecasting represents one of the most complex challenges in applied sciences, where the dynamic nature of models and the presence of hidden structures within data make it difficult to construct a single paradigm that offers both high accuracy and interpretability. In an increasingly data-driven world-where financial markets, education systems, and public policies demand data-informed decisions-the development of sophisticated predictive models is no longer merely an academic pursuit but a practical necessity. Linear models such as ARIMA have, for decades, provided a solid foundation for analyzing stationary time series, while artificial neural networks (ANNs) have emerged as powerful alternatives for capturing nonlinearity and underlying complexities. However, in many real-world applications, these models fail to capture all structural components of a time series when used in isolation, often resulting in limited or unstable predictions.

In this context, the present study develops and analyzes a hybrid ARIMA-ANN model, which integrates the linear descriptive power of autoregressive models with the nonlinear learning capabilities of NAR neural networks to enhance forecasting performance. The methodological framework is applied to four practical cases closely related to Albania's economic and social development: the Euro/ALL exchange rate, the daily price of Bitcoin, the results of the national high school graduation exam (Matura), and the motivation levels of lecturers in technical higher education. Each case follows standard procedures in time series analysis, including stationarity testing (using the ADF test), construction of SARIMA models, splitting datasets into training and testing subsets, and carefully tuning neural network parameters. The objective is not only to achieve high forecasting accuracy but also to demonstrate that combining classical statistical knowledge with artificial intelligence yields measurable advantages over traditional approaches.

The empirical results, evaluated using performance indicators such as RMSE, MAE, MPE, and MAPE, show that the hybrid model consistently outperforms single-model approaches across all examined cases. For instance, in the case of Matura exam results, relative errors were reduced by over 90% compared to the baseline ARIMA model. These outcomes are not only statistically significant but also practically relevant, offering insights for improving institutional decision-making, financial risk management, and educational policy design. In conclusion, this dissertation contributes to the existing literature by providing a robust and extensible framework for time series forecasting, with concrete applicability in the Albanian context and clear potential for adaptation in other critical sectors of national development.

Keywords: time series, modeling, forecasting, ARIMA, ANN, Hybrid ARIMA-ANN model.

MIRËNJOHJE

Ky punim nuk do të ishte bërë i mundur pa bashkëpunimin dhe mbështetjen e shumë njerëzve për të cilët do të jem mirënjohëse gjithë jetën, por do të veçoja dy miket e mia të zemrës Besjana Mema dhe Lorena Saliaj .

Falenderoj gjithashtu Profesorët e Shkollës Doktorale dhe kolegët e Fakultetit të Informatikës në Universitetin Mesdhetar të Shqipërisë për ndihmesën e dhënë.

Një mirënjohje e veçantë i shkon udhëheqëses sime shkencore, Prof. Asoc. Dr. Teuta Xhindi, e cila me profesionalizmin, mirësinë, këshillat e vyera, ndihmën e vazhdueshme, bashkëpunimin, sugjerimet e dhëna dhe inkurajimin e saj ka qenë një shtysë e rëndësishme për të ecur përpara në realizimin e këtij studimi.

Faleminderit nga zemra për gjithçka më keni dhënë si nga ana shkencore dhe humane!

Falenderoj gjithashtu familjen time, bashkëshortin Dorjan dhe dy fëmijët e mi Darjel e Esra për mbështetjen, inkurajimin dhe mirëkuptimin për orët e munguara në familje.

TABELA E PËRMBAJTJES

Abstrakt	i
Abstract	ii
Mirënjohje	iii
Lista e Figurave	ix
Lista e Tabelave	xi
Lista e Grafikëve	xiii
Lista e Shkurtimeve.....	xv
KAPITULLI 1.....	1
HYRJE	1
1.1 Korniza Paraprake mbi Rastin e Studimit.....	3
1.2 Roli i Parashikimit Inteligjent në Politikëbërjen Ekonomike dhe Institucionale.....	8
1.3 Objektivat dhe Pyetjet Kërkimore.....	9
1.4 Kufizimet e Studimit	11
1.5 Permbledhja e Tezës.....	12
KAPITULLI 2.....	15
RISHIKIM LITERATURE	15
2.1 Kërkimet në parashikimin e serive kohore me modelin ARIMA.....	16
2.1.1 Kërkimet në parashikimin e serive kohore me modelet parametrike.....	16
2.1.2 Kërkimet në parashikimin e serive kohore me modelin ANN	17
2.1.3 Kërkimet në parashikimin e serive kohore me modelet hibride.....	22
2.1.4 Kërkimet në parashikimin e serive kohore me modelin ARIMA-ANN.....	23
2.2 Konceptet Bazë të Parashikimit të Serive Kohore.....	25
2.2.1 Seritë Kohore	25
2.2.2 Stacionariteti.....	26
2.2.3 Testi i rrënjëve unitare.....	27

2.2.4 Testi Dickey-Fuller i përgjithësuar (ADF)	28
2.2.5 Kriteret e përzgjedhjes së modeleve.....	29
2.2.6 Vlefshmëria e Parashikimit	31
2.3 Modelet Lineare të Serive Kohore	33
2.3.1 Modele autoregresive të rendit p, AR(p).....	34
2.3.2 Modelet mesatare rrëshqitëse	34
2.3.3 Modelet ARMA(p,q)	35
2.3.4 Modelet ARIMA(p,d,q).....	35
2.3.5 Modelet SARIMA(p,d,q)(P,D,Q) _k	35
KAPITULLI 3.....	37
RRJETET NEURALE ARTIFICIALE	37
3.1 Nxënia Automatike.....	37
3.1.1 Nxënia e mbikëqyrur	38
3.1.2 Nxënia e pa mbikëqyrur	39
3.2 Rrjetat Neurale Artificiale (ANN).....	40
3.2.1 Çfarë është një Rrjet Neural?	40
3.2.2 Modelimi i ANN	41
3.2.3 Perceptroni	44
3.2.4 Perceptroni me shumë shtresa (MLP)	47
3.2.5 Rrjetat Neurale Jolineare Autoregresive (NARNN).....	54
3.3 Modeli Parashikues i Rrjetit Neural.....	56
KAPITULLI 4.....	63
MODELET KLASIKE DHE MODERNE PËR ANALIZIMIN DHE PARASHIKIMIN E SERIVE KOHORE	63
4.1 Arkitektura e Kombinimit-1.....	64
4.2 Arkitektura e Kombinimit-2.....	66
4.3 Arkitektura e Kombinimit-3.....	67
4.4 Metoda e Propozuar	68

KAPITULLI 5.....	71
METODOLOGJIA.....	71
5.1 Përzgjedhja e Rasteve të Studimit dhe Burimet e të Dhënave.....	72
5.2 Rastet e Studimit dhe Trajnimi Metodologjik.....	73
5.2.1 Kursi i këmbimit EURO/LEK.....	73
5.2.2 Çmimi ditor i Bitcoin-it.....	74
5.2.3 Rezultatet e Provimeve të Maturës Shtetërore.....	75
5.2.4 Motivimi i Lektoreve në Fakultetet e Inxhinierisë.....	76
5.3 Zbatimi Teknik dhe Vlerësimi i Performancës.....	77
5.4 Ndarja e të dhënave për Trajnim, Validim dhe Testim.....	78
KAPITULLI 6.....	81
REZULTATET E PUNIMIT.....	81
6.1 Seria Kohore e Çmimit ditor të Bitcoin-it.....	81
6.1.1 Analiza Përshkruese.....	81
6.1.2 Analiza Grafike.....	82
6.1.3 Modeli SARIMA i Çmimit ditor të Bitcoin-it.....	85
6.1.4 Parashikimi ARIMA.....	87
6.1.5 Modeli NAR i Çmimit ditor të Bitcoin-it.....	88
6.1.6 Modeli Hibrid ARIMA-ANN i Çmimit ditor të Bitcoin-it.....	90
6.1.7 Matja e Performancës.....	94
6.1.8 Kufijtë e Parashikueshmërisë dhe Risku Financiar.....	95
6.2 Seria Kohore e Rezultatet e Provimeve të Maturës Shtetërore.....	96
6.2.1 Analiza Përshkruese.....	96
6.2.2 Analiza Grafike.....	96
6.2.3 Modeli SARIMA për Serinë Kohore të Rezultateteve të Provimeve të Maturës Shtetërore.....	101
6.2.4 Parashikimi ARIMA.....	102

6.2.5 Modeli NAR i Serisë Kohore të Rezultateve të Provimeve të Maturës Shtetërore	104
6.2.6 Modeli Hibrid ARIMA-ANN për Seria Kohore e Rezultatet e Provimeve të Maturës Shtetërore	106
6.2.7 Matja e Performancës së Modeleve.....	110
6.2.8 Kufizime Interpretative dhe përdorimi Etik i Rezultateve	111
6.3 Seria Kohore e Motivimi i Lektorëve në Fakultetet e Inxhinierisë.....	112
6.3.1 Analiza Përshkruese	112
6.3.2 Analiza Grafike e Motivimi i Lektorëve në Fakultetet e Inxhinierisë.....	113
6.3.3 Modelimi i Serisë	114
6.3.4 Modeli Sezonal ARIMA për Motivimi i Lektorëve në Fakultetet e Inxhinierisë	117
6.3.5 Parashikimi ARIMA	119
6.3.6 Modeli NAR i Motivimi i Lektorëve në Fakultetet e Inxhinierisë.....	120
6.3.7 Modeli Hibrid ARIMA-ANN për Serinë kohore Motivimi i Lektorëve në Fakultetet e Inxhinierisë	122
6.3.8 Matja e Performancës së Modeleve	126
6.3.9 Implikime për Menaxhimin Institucional dhe Produktivitetin Akademik	127
6.4 Seria Kohore e Kursit të Këmbimit Euro/Lek.....	128
6.4.1 Analiza Grafike	128
6.4.2 Modeli SARIMA i kursit të këmbimit Euro/Lek	134
6.4.3 Parashikimi ARIMA	135
6.4.4 Modeli i rrjetit NAR i kursit të këmbimit Euro/Lek	137
6.4.5 Modeli hibrid ARIMA-ANN i kursit Euro/Lek	139
6.4.6 Matja e Performancës së Modeleve	143
6.4.7 Implikime për Politikën Monetare dhe Menaxhimin e Riskut Valutor.....	144
KAPITULLI 7.....	145

KONKLUSIONE DHE REKOMANDIME	145
7.1 Konkluzione	145
7.1.1 Përmbledhje e përgjithshme e rezultateve dhe përmbushja e objektivave kërkimorë	145
7.1.2 Vlerësimi i pyetjeve dhe hipotezave kërkimor.....	146
7.1.3 Kufizime në Transferueshmërinë Ekonomike të modeleve dhe vlerësimi kosto-përfitim i përdorimit të ANN.....	152
7.2 Rekomandime për kërkime të ardhshme dhe zbatim praktik	152
7.2.1 Kursi i këmbimit euro/lek	153
7.2.2 Çmimi ditor i bitcoin-it	160
7.2.3 Rezultatet e maturës shtetërore.....	161
7.2.4 Motivimi i lektorëve në fakultetet e inxhinierisë	162
7.2.5 Rekomandime të përgjithshme për kërkime dhe zbatim institucional	163
7.3 Përmbyllje	164
7.4 Reflektim mbi rolin dhe kufijtë e përdorimit të modeleve parashikuese	166
REFERENCAT	167
SHTOJCA A.....	175
SHTOJCA B.....	179
SHTOJCA C.....	182

LISTA E FIGURAVE

Figurë 1. Rregulli i Nxënies së Mbikëqyrur	38
Figurë 2. Rregulli i Nxënies së pa Mbikëqyrur	38
Figurë 3. Një Rrjet Neural Biologjik	39
Figurë 4. Arkitektura e Rrjetit Neural Artificial	41
Figurë 5. Skema e Një Neuronit	42
Figurë 6. Perceptroni Me Dy Hyrje	44
Figurë 7. Rrjeti Neural Me Dy Shtresa të Fshehura	48
Figurë 8. Rrjeti me Prapapërhapje me tri Shtresa	49
Figurë 9. Arkitektura e Rrjetit Neural NAR	55
Figurë 10. Struktura e Arkitekturës së Kombinimit -1	65
Figurë 11. Struktura e Arkitekturës së Kombinimit -2	66
Figurë 12. Struktura e Arkitekturës së Kombinimit -3	68
Figurë 13. Arkitektura e Modelit Të Propozuar Hibrid ARIMA-ANN	70
Figurë 14. Tregon ndarjen e të dhënave për: a) çmimin e Bitcoin-it, b) rezultatet e Maturës Shtetërore, c) Motivimin e Lektorëve, d) kursin e këmbimit Euro/Lek	80
Figurë 15. Inversi i Rrënjëve	86
Figurë 16. Arkitektura e Rrjetit Neural NAR Për Serinë Kohore të Çmimit Ditor të Bitcoin-it.....	89
Figurë 17. Arkitektura e Modelit Hibrid ARIMA-ANN e Çmimit Ditor të Bitcoin-it	92
Figurë 18. Testi ADF Mbi Serinë Kohore të Rezultateve të Provimeve të Maturës Shtetërore	98
Figurë 19. Inversi i Rrënjëve Për Rezultatet e Provimeve të Maturës Shtetërore	102
Figurë 20. Arkitektura e Rrjetit NAR Për Rezultatet e Provimeve të Maturës Shtetërore	104

Figurë 21. Rrjeti i Modelit Hibrid ARIMA-ANN Për Rezultatet e Provimeve të Maturës Shtetërore	107
Figurë 22. Shpërbërja e Serisë Kohore e Motivimit të Lektorëve në Fakultetet e Inxhinierisë.....	114
Figurë 23. Inversi i Rrënjëve Për Motivimin e Lektorëve në Fakultetet e Inxhinierisë	117
Figurë 24. Arkitektura e Rrjetit NAR Për Motivimin e Lektorëve në Fakultetet e Inxhinierisë.....	120
Figurë 25. Arkitektura e Rrjetit të Modelit ARIMA-ANN Për Motivimin e Lektorëve në Fakultetet e Inxhinierisë	123
Figurë 26. Skema e Një Cikli Tipik të Biznesit	129
Figurë 27. Testi ADF Për Kursin e Këmbimit Euro/Lek	131
Figurë 28. Inversi i Rrënjëve Për Kursin e Këmbimit Euro/Lek	134
Figurë 29. Arkitektura e Rrjetit NAR për Kursin e Këmbimit Euro/Lek.....	137
Figurë 30. Arkitektura e Modelit Hibrid ARIMA-ANN Për Serinë Kohore të Kursit të Këmbimit Euro/Lek.....	141

LISTA E TABELAVE

Tabelë 1. Ngjashmëria Ndërmjet Rrjetit Neural Biologjik Dhe Atij Artificial	41
Tabelë 2. Përmbledhëse e Metodologjisë për Raste Studimore	71
Tabelë 3. Tabela Me Karakteristikat e Rrjetit Neural të Modelit Hibrid ARIMA-ANN	91
Tabelë 4. Peshat Sinaptike të Modelit Hibrid ARIMA-ANN Për Çmimin Ditor të Bitcoin-it.....	93
Tabelë 5. Treguesit e Saktësisë Për Tri Modelet e Serisë Kohore të Çmimit Ditor të Bitcoin-it.....	94
Tabelë 6. Treguesi U e Theil-it Për Tri Modelet e Serisë Kohore të Çmimit Ditor të Bitcoin-it.....	95
Tabelë 7. Të Dhënat e Modelit Hibrid ARIMA-ANN Për Rezultatet e Provimeve të Maturës Shtetërore	106
Tabelë 8. Tabela Me Peshat Sinaptike të Rrjetit Hibrid Për Rezultatet e Provimeve të Maturës Shtetërore	108
Tabelë 9. Treguesit e Performancës së Tri Modeleve Për Rezultatet e Provimeve të Maturës Shtetërore	109
Tabelë 10. Vlera e U e Theil-it Për Tri Modelet e Rezultateve të Provimeve të Maturës Shtetërore	110
Tabelë 11. Të Dhënat e Rrjetit Hibrid	122
Tabelë 12. Peshat Sinaptike të Rrjetit Neural	124
Tabelë 13. Treguesit e Performancës së Tri Modeleve Për Motivimin e Lektorëve Në Fakultetet e Inxhinierisë	126
Tabelë 14. Vlera Statistike U e Theil-it Për Tri Modelet e Motivimit të Lektorëve në Fakultetet e Inxhinierisë	126
Tabelë 15. Të Dhënat e Parametrave Të Rrjetit Hibrid Për Kursin e Këmbimit Euro/Lek.....	140
Tabelë 16. Të Dhënat e Peshave Sinaptike Të Rrjetit Hibrid të Euro/Lek	142
Tabelë 17. Treguesit e Performancës Së Tri Modeleve për Kursin e Këmbimit Euro/Lek.....	143

Tabelë 18. Treguesi U e Theil-it Për Tri Modelet për Kursin e Këmbimit Euro/Lek	137
--	-----

LISTA E GRAFIKËVE

Grafiku 1. Funkzionet e Aktivizimit	43
Grafiku 2. Ndarja Lineare e Perceptronit Me Dy Hyrje	44
Grafiku 3. Plani Ndarës Në Perceptronin Me Tri Hyrje	45
Grafiku 4. Modifikimi i Peshave Në Mënyrë Gradiente	50
Grafiku 5. Grafiku i Ecurisë së Çmimit Ditor të Bitcoin-it	82
Grafiku 6. Grafiku i Dekompozimit të Serisë së Çmimit Ditor të Bitcoin-it	83
Grafiku 7. Korrelogramat e ACF Dhe PACF Për Çmimin Ditor të Bitcoin-it	84
Grafiku 8. Korrelogramat e ACF Dhe PACF Pas Diferencimit Për Çmimin Ditor të Bitcoin-it.....	84
Grafiku 9. Parashikimi me Modelin ARIMA i Çmimit Ditor të Bitcoin-it	87
Grafiku 10. SARIMA Kundrejt Serisë Kohore të Çmimit Ditor të Bitcoin-it	87
Grafiku 11. Parashikimi i Rrjetit Neural NAR Për Serinë Kohore të Çmimit Ditor të Bitcoin-it.....	89
Grafiku 12. Rrjeti Neural NAR Kundrejt Serisë Origjinale të Çmimit Ditor të Bitcoin-it	90
Grafiku 13. ARIMA-ANN Kundrejt Serisë Origjinale të Çmimit Ditor të Bitcoin-it	94
Grafiku 14. Seria Kohore e Rezultateve të Provimeve të Maturës Shtetërore	97
Grafiku 15. Korrelogramat ACF Dhe PACF Për Rezultatet e Provimeve të Maturës Shtetërore	99
Grafiku 16. Korrelogramat ACF Dhe PACF Pas Diferencimit të Rezultateve të Provimeve të Maturës Shtetërore	100
Grafiku 17. Parashikimi ARIMA i Rezultateve të Provimeve të Maturës Shtetërore	102
Grafiku 18. SARIMA Kundrejt Serisë Kohore të Rezultateve të Provimeve të Maturës Shtetërore	103
Grafiku 19. Parashikimi i Rrjetit NAR për Serinë Kohore të Rezultateve të Provimeve të Maturës Shtetërore	105

Grafiku 20. NAR Kundrejt Serisë Kohore për Rezultateve e Provimeve të Maturës Shtetërore	105
Grafiku 21. Modeli ARIMA-ANN Kundrejt Serisë Kohore për Rezultatet e Provimeve të Maturës Shtetërore	109
Grafiku 22. Seria Kohore e Motivimit të Lektorëve në Fakultetet e Inxhinierisë	112
Grafiku 23. Korrelogramat ACF Dhe PACF Për Motivimin e Lektorëve në Fakultetet e Inxhinierisë	115
Grafiku 24. Parashikimi ARIMA Për Motivimin e Lektorëve në Fakultetet e Inxhinierisë.....	118
Grafiku 25. SARIMA Kundrejt Serisë Kohore të Motivimit të Lektorëve në Fakultetet e Inxhinierisë	119
Grafiku 26. Parashikimi i Rrjetit NAR Në Motivimin e Lektorëve në Fakultetet e Inxhinierisë.....	120
Grafiku 27. NAR Kundrejt Serisë Kohore të Motivimit të Lektorëve në Fakultetet e Inxhinierisë.....	121
Grafiku 28. ARIMA-ANN Kundrejt Serisë Kohore të Motivimit të Lektorëve në Fakultetet e Inxhinierisë	125
Grafiku 29. Komponentja Sezonale në Serinë e Kursit të Këmbimit Euro/Lek	129
Grafiku 30. Seria Kohore e Kursit të Këmbimit Euro/Lek	130
Grafiku 31. Korrelogramat ACF Dhe PACF Për Kursin e Këmbimit Euro/Lek	132
Grafiku 32. Parashikimi ARIMA Për Kursin e Këmbimit Euro/Lek	135
Grafiku 33. SARIMA Kundrejt Serisë Kohore të Kursit të Këmbimit Euro/Lek	136
Grafiku 34. Parashikimi i Rrjetit NAR në Serinë e Kursit të Këmbimit Euro/Lek	138
Grafiku 35. NAR Kundrejt Serisë Kohore të Kursit të Këmbimit Euro/Lek	138
Grafiku 36. ARIMA-ANN Kundrejt Serisë Kohore të Kursit të Këmbimit Euro/Lek	143

LISTA E SHKURTIMEVE

ACF	Autocorrelation Function
ADF	Augmented Dickey Fuller
ANN	Artificial Neural Network
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
BP	Backpropagation
TFR	Total RPM Rate
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MLP	Multi Layer Perceptron
MPE	Mean Percentage Error
MSE	Mean Squared Error
NAR	Nonlinear Autoregressive
NARNN	Nonlinear Autoregressive Neural Network
PACF	Partial Autocorrelation Function
RMSE	Root Mean Squared Error
RProp	Resilient Backpropagation
SARIMA	Seasonal Autoregressive Integrated Moving Average
SSE	Sum Squared Error
RPM	Rezultatet e Provimeve të Maturës Shteterore
MLFI	Motivimi i Lektorëve në Fakultetin e Inxhinierisë
Bit	Çmimit ditor të Bitcoin-i
IB	Inteligjenca e Biznesit
MIS	Menaxhimit të Informacionit
EMIS	Education Management Information System
HRM	Human Resource Management

KAPITULLI 1

HYRJE

Në një epokë të karakterizuar nga ndryshime të shpejta teknologjike dhe dinamika të vazhdueshme ekonomike, aftësia për të parashikuar me saktësi të dhënat e së ardhmes përbën një element thelbësor për vendimmarrjen strategjike në shumë sektorë. Nga tregjet financiare dhe bankat qendrore, te qeveritë dhe institucionet arsimore, të gjithë aktorët përballen me nevojën për të kuptuar dhe për të parashikuar zhvillimet e ardhshme përmes analizës së të dhënave historike. (Chen *et. al.*, 2007; Kumar & Thenmozhi, 2012). Në këtë kuadër, analiza dhe modelimi i serive kohore është bërë një ndër fushat më të rëndësishme të kërkimit shkencor dhe aplikimit praktik në statistika, ekonomi, teknologji informative dhe inteligjencë artificiale.

Seritë kohore përfaqësojnë sekuenca të të dhënave të renditura në kohë, të cilat reflektojnë zhvillimin e një dukurie të caktuar qoftë ai ekonomik, social apo teknologjik. Të dhënat kohore janë të kudogjendura: nga çmimi ditor i Bitcoin-it dhe kurset e këmbimit valutor, deri te çmimet e aksioneve, treguesit e performancës arsimore apo edhe nivelet e kënaqësisë së punonjësve në sektorin akademik. (Hamzacebi, 2008; Kihoro, *et. al.*, 2004). Këto seri mbartin informacion të vlefshëm që, nëse interpretohet dhe analizohet në mënyrë të saktë, mund të ndihmojë në optimizimin e strategjive institucionale dhe rritjen e konkurrueshmërisë në treg.

Tradicionalisht, modelimi i serive kohore është dominuar nga qasjet statistikore, ku modelet lineare si ARIMA¹ (modele autoregresive me mesatare rrëshqitëse të integruara) kanë zënë një vend të rëndësishëm për shkak të thjeshtësisë, fleksibilitetit dhe fuqisë shpjeguese në analizimin e të dhënave që shfaqin komponentë trend dhe sezonale. Këto modele janë të përshtatshme për seri që i nënshtrohen një strukture të rregullt, lineare, ku vlerat e mëparshme të serisë ofrojnë informacion të mjaftueshëm për të parashikuar të ardhmen. Por, me zhvillimin e tregjeve dhe rritjen e kompleksitetit të fenomeneve ekonomike dhe sociale, është bërë gjithnjë e më e qartë se modelet lineare nuk mund të përballojnë në mënyrë të mjaftueshme jolinearitetin dhe paqëndrueshmërinë që karakterizon të dhënat reale. (Gvaladze, 2015).

Kjo ka çuar në zhvillimin dhe përdorimin në rritje të teknikave më të sofistikuar, ndër të cilat spikasin modelet e inteligjencës artificiale. Rrjetet Neurale Artificiale (ANN²), të frymëzuara nga funksionimi i trurit të njeriut, ofrojnë një alternativë shumë më të fuqishme për të modeluar marrëdhënie komplekse, jolineare mes variablave. Ato nuk kërkojnë njohuri të mëparshme për shpërndarjen statistikore të të dhënave dhe janë të afta të mësojnë në mënyrë adaptive, duke përmirësuar parashikimet me çdo iteracion të trajnimit. (Kutbatsky *et. al.*, 2011). ANN janë përdorur me sukses në një gamë të gjerë aplikimesh, duke përfshirë klasifikimin, njohjen e imazheve, përpunimin e gjuhës

¹ AutoRegressive Integrated Moving Average

² Artificial Neural Network

natyrore dhe së fundmi edhe në parashikimin e serive kohore. Megjithatë, edhe rrjetet neurale nuk janë të përsosura. Ato kërkojnë sasi të mëdha të dhënash, janë të ndjeshme ndaj mbimësimit të të dhënave të trajnimit, dhe shpesh mungon interpretueshmëria e qartë e modeleve të krijuara. Për këtë arsye, është propozuar një qasje alternative ajo hibride, e cila përpiket të kombinojë përparësitë e modeleve lineare me fleksibilitetin e metodave jolineare.

Modelet hibride, si ai ARIMA-ANN³, synojnë të kapin komponentët trend dhe sezonale me ARIMA, ndërsa komponentët e mbetura dhe jolineare t'i modelojnë përmes rrjeteve neurale. Ky integrim ka rezultuar në përmirësim të ndjeshëm të performancës së parashikimit në shumë raste është i dokumentuar në literaturën ndërkombëtare.

Studimi i realizuar në këtë disertacion është ndërtuar mbi këtë filozofi hibride. Tseng *et. al.*, (2002). Duke njohur kufizimet e secilës qasje të veçuar, si dhe kërkesat gjithnjë e më të larta për saktësi në parashikim, është zhvilluar një model i integruar ARIMA-ANN i cili aplikohet në katër seri kohore të përzgjedhura për rëndësinë e tyre ekonomike dhe sociale në kontekstin shqiptar: kursi i këmbimit Euro/Lek, çmimi ditor i Bitcoin-it, rezultatet e provimeve të maturës shtetërore dhe motivimi i lektorëve në fakultetin e inxhinierisë.

Zgjedhja e këtyre serive nuk është e rastësishme. Kursi i këmbimit Euro/Lek është një nga treguesit më të ndjeshëm për stabilitetin ekonomik të vendit, i ndikuar nga faktorë të brendshëm dhe të jashtëm, si politika monetare, bilanci tregtar dhe remitancat. Luhatjet e tij ndikojnë në vendimmarrjen e sipërmarrjeve, konsumatorëve dhe institucioneve.

Çmimi i Bitcoin-it, nga ana tjetër, përfaqëson një treg të ri, inovativ, por ekstremisht të paqëndrueshëm, i cili po fiton gjithnjë e më shumë terren në sistemin financiar global dhe mund të ndikojë indirekt në ekonominë në zhvillim si Shqipëria.

Rezultatet e provimeve të maturës shtetërore janë tregues të rëndësishëm për performancën e sistemit arsimor, me implikime të drejtpërdrejta në politikat edukative. Ndërsa motivimi i stafit akademik ndikon në cilësinë e mësimdhënies dhe prodhimin shkencor, duke qenë një komponent kyç për zhvillimin institucional të universiteteve. Për të realizuar këtë studim, është ndjekur një metodologji e strukturuar në disa faza. Fillimisht është bërë analizimi eksplorues i të dhënave për të vlerësuar karakteristikat themelore të secilës seri kohore. Më pas janë ndërtuar modele të veçanta për secilën seri, përkatësisht me metodën ARIMA dhe ANN, duke vlerësuar performancën e tyre përmes treguesve standardë si RMSE⁴, MAE⁵, MAPE⁶ dhe koeficienti U i Theil-it. Në

³ AutoRegressive Integrated Moving Average – Artificial Neural Network

⁴ Root Mean Squared Error

⁵ Mean Absolute Error

⁶ Mean Absolute Percentage Error

fazën finale, është zhvilluar modeli hibrid ARIMA-ANN dhe është bërë krahasimi i rezultateve me modelet individuale. Gjetjet e studimit kanë treguar se qasja hibride ka një avantazh të qartë në saktësinë e parashikimit, duke tejkaluar modelet tradicionale në shumicën e rasteve të analizuara. Kjo vërteton hipotezën kryesore të këtij disertacioni: se kombinimi i teknikave lineare dhe jolineare është një strategji më efikase për trajtimin e problemeve reale të modelimit të serive kohore.

Përveç kontributit teorik, studimi ka vlerë edhe në aspektin praktik. Modelet e zhvilluara mund të integrohen në sistemet vendimmarrëse të institucioneve financiare, agjencive shtetërore, universiteteve dhe sipërmarrjeve, duke ndihmuar në planifikimin më të mirë të politikave dhe burimeve. Kjo është veçanërisht e rëndësishme për vende si Shqipëria, ku nevoja për mjete moderne analitike është në rritje, por kapacitetet ekzistuese janë ende në zhvillim.

1.1 KORNIZA PARAPRAKE MBI RASTIN E STUDIMIT

Dizenjimi i një metode që të sigurojë parashikim të mirë përbën një sfidë. Metodrat e parashikimit lidhen me idenë se e kaluara na tregon diçka për të ardhmen. Çështja se si do të interpretohen saktësisht informacionet e koduara në ngjarjet e kaluara, përbën pjesën kryesore të analizës së serive kohore. Studimi i analizës së serive kohore ka lindur me nevojën për të kuptuar dinamikën e luhatjeve të të dhënave të gjeneruara nga një model i panjohur. Dinamikat shihen si ndryshime të vlerave gjatë një kohe të caktuar të ndryshores në studim. Këto luhatje gjenden në lloje të ndryshme të dhënash, në varësi të fushës së zbatimit.

Për shumë kohë, seritë kohore janë bazuar vetëm në metodat statistikore. Janë përdorur për një kohë të gjatë tipe të ndryshme modelesh statistikore lineare. Midis tyre, modelet e njohura Box-Jenkins (Box & Jenkins, 1970) ARIMA janë më të përdorurat në parashikimin e serive kohore kryesisht në ekonomi. Sidoqoftë, këto janë modele lineare ndërkohë që, shumica e problemeve reale gjenden në formë jolineare. Kjo përbën kufizim në zbatimin e këtyre metodave.

Me qëllim që të tejkalohen kufizime të tilla, janë propozuar dhe zhvilluar në kohë modele statistikore jolineare. Të metat e këtyre modeleve janë kompleksiteti i lartë matematikor dhe nevoja gjatë gjithë kohës për specialistë që të vlerësojnë parashikimet e gjeneruara. Yu, *et. al.*, (2014). Përveç kësaj, mjedisi dinamik i serive kohore, nevoja për përzgjedhje të vazhdueshme të modeleve e një sërë funksionesh të tjera që kanë lidhje me parashikimin e serive, bën të nevojshme përdorimin e sistemeve automatike. Sisteme të tilla gjenerojnë vetë modelet, i përditësojnë ato, i përmirësojnë, njohin dhe parashikojnë një shumëllojshmëri serish kohore në mënyrë efikase pa ndërhyrjen e njerëzve. Ndërkohë që, tregjet financiare po ndikoheshin gjithnjë e më shumë nga teknologjia, disa investitorë dhe studiues e kuptuan se, ekzistonte një fuqi e madhe te sistemet kompjuterike, të cilat mund të kryenin një sërë funksionesh pa ndërhyrje njerëzore. (Vika, 2016; Dara, 2015).

Kështu u ndërtuan sistemet e para të ashtuquajtura sisteme tregtare të automatizuara. Teksa teknologjia kompjuterike po përhapej gjithnjë e më shumë, këto sisteme u sofistikuan. Nga fundi i viteve 80' sistemet komplekse të tregtimit automatik ishin një dukuri e zakonshme në tregjet amerikane, veçanërisht për institucionet e pasura. Integrimi i teknologjisë me rregullat dhe strategjitë ekonomike të përdorura nga bizneset për analizën të dhënave ka krijuar fushën që njihet me emrin Inteligjenca e Biznesit (IB). IB përdor softuerët për të transformuar të dhënat në inteligjencën e zbatueshme për të orientuar sjelljen dhe vendimet strategjike të një biznesi.

Zhvillimi i metodave automatike në fushën e ekonomisë është rritur së tepërmi, duke arritur te metodat e sotme inteligjente, pjesë e Inteligjencës Artificiale. Kohët e fundit seritë kohore po modelohen me anë të metodave të inteligjencës artificiale. (Politof & Ulmer, 1998; Bouqata *et. al.*, 1999; Enke & Mehdiyev, 2012). Teknika si Rrjetat Neurale, Pemët e Vendimit, Vektorët Mbështetës apo Algoritmet Gjenetikë, janë disa nga format që përdoren për modelim dhe parashikim.

Në këtë studim do të përdoret një nga këto metoda, konkretisht Rrjeti Neural Artificial (ANN). Do të prezantohen tiparet e tij, cilësitë dhe të metat. Lexuesi do të njihet me format e zbatimit të tij në parashikim duke mundësuar një propozim sa më efikas të modelit parashikues që do të përdoret për rastet e serive kohore në studim.

Metodat lineare janë të thjeshta për t'u zhvilluar dhe interpretuar, por kanë kufizime të mëdha në momentin kur duhet të njohin marrëdhëniet jolineare të të dhënave. Përafrimi i modeleve lineare për marrëdhëniet komplekse jolineare nuk është gjithmonë i kënaqshëm. Ndaj, nevojitet integrimi i modeleve jolineare.

Sistemet moderne, rrjetat neurale (ANN) janë një ndër modelet më të përdorura në fushën e parashikimit të serive kohore. Ato janë teknika jolineare, gjë që i bën më të përshtatshme në modelimin e modeleve komplekse të të dhënave. Rrjetat neurale janë teknika për përafrimin e funksioneve, të cilat mësojnë marrëdhënien ndërmjet hyrjeve dhe daljeve. Areekul, *et. al.*, (2010). Ato nuk bëjnë supozime apo hamendësime rreth shpërndarjes statistikore, ose veçorive të të dhënave. Për këtë arsye tentojnë të jenë më të dobishme në situata praktike. ANN janë elastike, në gjendje të punojnë në mënyrë paralele me ndryshoret hyrëse dhe për pasojë mund të trajtojnë grupe të mëdha të dhënash. Teknikat statistikore në parashikim kanë arritur limitin e tyre në zbatim të të dhënave jolineare (Refenes *et. al.*, 1994). ANN jo vetëm që mund të trajtojnë strukturat jolineare në një problem, por mund të modelojnë edhe proceset lineare, si seritë kohore lineare.

White (1989) ka sugjeruar se, marrëdhënia midis rrjetave neurale artificiale dhe metodave tradicionale statistikore është komplementare në parashikim. Të dy modelet ARIMA dhe ANN kanë pasur sukseset e tyre në modelimin linear ose jolinear. Megjithatë, asnjë prej tyre nuk është model universal, i përshtatshëm për të gjitha rastet. Yu *et. al.*, (2005). Duke qenë se është e vështirë të njihen plotësisht karakteristikat e të

dhënave në një problem real, metodologjia hibride me aftësi modelimi lineare dhe jolineare mund të jetë një strategji e mirë për përdorim praktik. Nga kombinimi i modeleve të ndryshme mund të njihen tipare të ndryshme të serive që studiohen (Zhang, 2003). Në këtë studim do të zhvillohet analiza e katër serive kohore me idenë për të parashikuar trendin e një ndryshoreje ekonomike duke vlerësuar të dhëna si; kursi i këmbimit Euro/Lek, çmimi ditor i Bitcoin-it, rezultatet e provimeve të maturës shtetërore dhe motivimi i lektorëve në fakultetin e inxhinierisë.

Studimet ndërkombëtare mbi çmimin e Bitcoin-it janë të shumta dhe përfshijnë analiza të volatilitetit, modelime me GARCH⁷, ARIMA dhe metoda të Machine Learning. Në Shqipëri, hulumtimet janë ende të kufizuara, kryesisht si pjesë e punimeve teorike mbi financat dixhitale dhe ndikimin e tyre potencial. Literatura sugjeron se çmimi i Bitcoin-it ndikohet nga faktorë të brendshëm të tregut (oferta dhe kërkesa), lajmet, rregulloret, spekulimet dhe faktorët globalë si luhatjet e dollarit. Puna e Zhang et al. (2020) tregon potencialin e ANN për të kapur modelet jolineare në çmimet e kriptomonedhave.

Të ndërtohet një model i integruar që kombinon të dhënat historike të çmimit ditor me tregues të lajmeve dhe faktorëve që reflektojnë perceptimet apo reagimet e tregut. Të testohen modele hibride (ARIMA-ANN) dhe algoritme të avancuara të Deep Learning për të kapur tipare të fshehura. Për Shqipërinë sugjerohet të shihet ndikimi i pranisë së tregjeve krypto mbi ekonominë informale dhe prirjet e investimeve.

Seria kohore që paraqet një interes të madh në këtë studim, për shkak të ndikimit të saj në zhvillimet financiare moderne, është çmimi i Bitcoin-it në tregun shqiptar. Ky tregues ka fituar rëndësi të veçantë në vitet e fundit, pasi ndikon gjithnjë e më shumë në vendimmarrjen financiare të individëve dhe bizneseve. Luhatjet e çmimit të Bitcoin-it mund të ndikojnë në mënyrën se si njerëzit kursejnë, investojnë apo mbrojnë vlerën e kapitalit të tyre në raport me monedhën vendase.

Kur çmimi i Bitcoin-it rritet, shumë persona e shohin atë si një mundësi fitimi dhe rrisin investimet në kriptomonedha, ndërkohë që në periudhat e rënies, priren të tërhiqen ose të ruajnë kapitalin në forma më të sigurta. Ky ndikim në sjelljen financiare individuale dhe kolektive e bën çmimin e Bitcoin-it një faktor me ndikim potencial në aktivitetin ekonomik, veçanërisht në mjedise me stabilitet të luhatshëm financiar. (Samia, *et. al.*, 2012). Në këtë mënyrë, Bitcoin-i nuk është vetëm një aset digjital, por edhe një reflektim i perceptimeve të tregut dhe i pritshmërive për të ardhmen ekonomike.

Shumica e studimeve tregojnë se kursi i këmbimit Euro/Lek ndikohet nga faktorë si bilanci tregtar, remitancat, politika monetare, si dhe faktorë gjeopolitikë. Engel et al. (2008) dhe të tjerë kanë treguar rëndësinë e kursit të këmbimit si një indikator i stabilitetit ekonomik. Në Shqipëri, literatura mbetet më shumë deskriptive dhe më pak e orientuar drejt metodave inteligjente të parashikimit.

⁷ Generalized AutoRegressive Conditional Heteroskedasticity

Sugjerohet të aplikohet një qasje hibride: të kombinohen modelet tradicionale ARIMA me rrjete neurale artificiale (ANN) për të modeluar komponentët linearë dhe jolinearë të serisë. Për më tepër, mund të integrohen edhe faktorë makroekonomikë për të pasur parashikime më të sakta, dhe të ndërtohen sisteme monitorimi të automatizuara që përditësojnë modelet në kohë reale

Lloji i treguesit të përdorur në këtë studim është kursi i këmbimit Euro/Lek, i cili përfaqëson raportin e konvertimit të monedhës vendase (leku) me monedhën euro. Ky kurs ka një rëndësi thelbësore për ekonominë shqiptare, pasi ndikon drejtpërdrejt në çmimet e mallrave të importuara, balancën tregtare, politikën fiskale dhe besimin e konsumatorëve. Kursi i këmbimit, i njohur ndryshe si “çmimi i valutës së huaj në monedhë vendase”, është i ndjeshëm ndaj një sërë faktorësh, përfshirë zhvillimet në tregjet ndërkombëtare, politikën monetare të Bankës së Shqipërisë, nivelin e inflacionit dhe flukset hyrëse dhe dalëse të kapitalit.

Në Shqipëri, kursi Euro/Lek përcaktohet nëpërmjet sistemit të kursit të lirë të këmbimit, ku çmimi formohet në bazë të ofertës dhe kërkesës në treg. Ky tregues përbën një nga kanalet kryesore nëpërmjet të cilave përçohen sinjalet e politikës monetare, veçanërisht në një ekonomi të hapur si Shqipëria, ku ekspozimi ndaj valutave të huaja është i lartë. Ndryshimet në kursin e këmbimit ndikojnë tërthorazi edhe te normat e interesit, inflacioni dhe nivelet e konsumit dhe investimeve.

Modelimi i kursit të këmbimit përbën një sfidë komplekse, për shkak të natyrës së tij të paqëndrueshme dhe ndikimit të faktorëve të shumtë ekonomikë dhe gjeopolitikë. Në Shqipëri, literatura mbi analizën sasiore të kursit të këmbimit është ende e kufizuar dhe kryesisht e përfshirë si pjesë e trajtimeve më të gjera ekonomike, gjë që thekson nevojën për studime më të thelluara dhe të specializuara në këtë fushë.

Në erën e re të globalizimit dhe liberalizimit financiar, kursi i këmbimit luan një rol kryesor në tregjet ndërkombëtare dhe në sistemin financiar të një vendi në zhvillim e sipër, si rasti i Shqipërisë. Kjo është arsyeja kryesore për të cilën është zgjedhur që të analizohet seria kohore e kursit Euro/Lek. Roli i kurseve të këmbimit cilësohet i rëndësishëm, sepse çdo ndryshim i tij prek çdo gur të sistemit financiar.

Një kurs i qëndrueshëm këmbimi ndihmon kompanitë dhe sipërmarrësit që të vlerësojnë performancën e investimeve të tyre, likuiditetin, aftësinë paguese, detyrimet dhe mbi të gjitha të kenë mundësi të parashikojnë situatën e tyre ekonomike për vitet e ardhshme (Engel, et. al., 2008). Kursi i këmbimit lidh ekonominë e një vendi me ekonominë e botës. Ai reflekton të gjitha transaksionet midis agjentëve ekonomikë, brenda dhe jashtë vendit. Për arsye të ndjeshmërisë që paraqet aktiviteti ekonomik ndaj kursit të këmbimit, një politikë e suksesshme makroekonomike nuk mund të zbatohet pa marrë parasysh edhe kurset e këmbimit. Luhatjet në kurset e këmbimit valutor janë ndoshta faktorët më të rëndësishëm që influencojnë shitjet, parashikimin e fitimit, planet për buxhetin e kapitalit dhe vlerën e investimeve të huaja. Nga ky këndvështrim,

ndryshimet në kurset e këmbimit valutor luajnë një rol të rëndësishëm në stabilitetin ekonomik e politik të botës në përgjithësi si dhe të mirëqenies së kombeve të marra në veçanti. Ndryshimet në kurset e këmbimit kanë pasojë të mëdha dhe këto të fundit e japin efektin e tyre në luhatshmërinë e faktorëve makroekonomikë.

Kursi i këmbimit Euro/Lek është një nga treguesit më të monitoruar në Shqipëri, për shkak të varësisë së madhe të ekonomisë shqiptare nga remitancat, importet dhe tregtia e jashtme. Studime të ndryshme kanë analizuar luhatshmërinë e tij përmes modeleve statistikore (ARIMA) dhe ndonjëherë edhe me qasje ekonometrike strukturore. Banka e Shqipërisë publikon rregullisht të dhëna historike, dhe janë bërë punime që lidhin kursin me inflacionin, normat e interesit dhe aktivitetet sezonale.

Nga ana tjetër, kjo është një çështje me rëndësi të veçantë për vetë kushtet e Shqipërisë ku vërehet një varësi e madhe nga tregtia e jashtme e nga të ardhurat e emigrantëve nga jashtë, çështje e cila shqetëson bankat e grupet e tjera të interesit. Tregtia dhe investimet e huaja realizohen në kuadrin e një sistemi monetar ndërkombëtar i përbërë nga sistemi i monedhës dhe lidhjet e tyre nëpërmjet tregjeve të kurseve të këmbimit valutor. Në Shqipëri, provimet e maturës shtetërore janë një nga temat më të diskutuara në fushën e arsimit. Deri më tani, analizat kanë qenë kryesisht statistike dhe raportuese (p.sh. nota mesatare, shpërndarja e rezultateve sipas qarqeve), por nuk ka shumë punime për modelimin parashikues të rezultateve në varësi të faktorëve të ndryshëm.

Theksohet se sukseset në testime ndikohen nga faktorë socio-ekonomikë, kualiteti i shkollës, motivimi personal dhe niveli i mësimdhënies. Modelet statistikore dhe rrjetet neurale janë përdorur për të parashikuar rezultatet individuale dhe trendin në nivel kombëtar. Të zhvillohet një model parashikimi që përfshin të dhëna demografike, historikun e rezultateve, faktorin socio-ekonomik dhe cilësinë e mësimdhënies. Një qasje hibride mund të ndihmojë për të identifikuar parregullsi, prirje dhe për të bërë plane për ndërhyrje në shkolla me performancë të ulët. Mund të kombinohet me sistemet e menaxhimit të informacionit arsimor për raportim automatik.

Studimet mbi motivimin e stafit akademik në Shqipëri janë ende të kufizuara. Shumica janë fokusuar në sondazhe për nivelin e kënaqësisë në punë, kushtet e punës, mbështetjen institucionale dhe faktorët financiarë. Literatura ndërkombëtare thekson se motivimi i lektorëve lidhet me faktorë si zhvillimi profesional, ambienti akademik, autonomia, shpërblimi dhe mundësitë për kërkim shkencor. Qasja përmes sistemeve të menaxhimit të informacionit (MIS) është relativisht e re dhe ka për qëllim të mbledhë dhe analizojë të dhëna në mënyrë të strukturuar. Sugjerohet të zhvillohen instrumente të dixhitalizuara për të monitoruar dhe përmirësuar motivimin: sondazhe të integruara periodike, analiza të dhënash mbi përmirësimin e objektivave, mundësi për feedback anonim, dhe ndërlidhja me politikën e burimeve njerëzore. Mund të përdoret Inteligjenca Artificiale për të identifikuar trende që lidhen me demotivimin dhe për të propozuar masa parandaluese.

Në këtë studim do të kryhet modelimi i plotë i serive të lartpërmendura parë në realitetin shqiptar. Me modelet e krijuara me një ndryshore kryhet parashikimi për periudhat në vazhdim. Analiza empirike do të përcaktojë efikasitetin e çdo modeli. Në varësi të modelimit do të zhvillohet parashikimi me modelin më të përshtatshëm ARIMA që do të përftohet. Po ashtu, kryhet kontrolli dhe verifikohet rrjeti neural si një metodë inteligjente parashikimi.

Projektimi i arkitekturës së rrjetit dhe trajnimi i saj me algoritmet e nxënies krijojnë strukturën e modelit për secilën nga ndryshoret në studim duke e mbyllur me parashikimin. Analizohet si do të funksionojë kjo metodë për rastet konkrete të zbatimit, në bazë të treguesve që masin performancën e modelit dhe të parashikimit. Në bazë të rezultateve të arritura gjendet se, cila prej teknikave të përdorura rezulton më e mirë, më e përshtatshme dhe më efektive. Për të arritur një performancë më të mirë, optimizuese të modelimit, përdoret modelimi hibrid.

Hibridizimi vjen nga kombinimi i të paktën dy teknikave. Arsyeja kryesore e hibridizimit është marrja e cilësive pozitive të teknikave të kombinuara në një metodë të vetme. (Lotfi Zadeh, 1996) ka cituar: “një kombinim i mirë do të ishte një ‘polic britanik’, ‘mekanik gjerman’, ‘kuzhinier francez’, ‘bankier zvicerian’ dhe një ‘i dashur italian’, ndërkohë që, një ‘kuzhinier britanik’, ‘polic gjerman’, ‘mekanik francez’, ‘bankier italian’ apo ‘i dashur zvicerian’ do të ishte një kombinim aspak eficient”. E njëjta logjikë qëndron dhe për sistemet hibride. Një sistem hibrid është eficient ose jo, në varësi të komponentëve të tij. Ndaj duhen zgjedhur metodat e duhura për ndërtimin e një sistemi të mirë hibrid.

Për të modeluar seritë, në studim janë zgjedhur teknika tradicionale ARIMA me teknikën inteligjente Rrjet Neural Artificial. Motivi i krijimit të këtij lloji modeli hibrid vjen nga disa perspektiva si, vështirësia në praktikë e përcaktimit të një serie kohore mbi linearitetin ose jolinearitetin e tij, ose shpesh i përmbajnë të dyja strukturat, për të cilat as modelet ARIMA e as ANN nuk janë të përshtatshme për modelim. Pra, ky problem mund të zgjidhet duke kombinuar modelet lineare ARIMA dhe ato jolineare ANN dhe për shkak se problemet janë shpesh komplekse në natyrë dhe çdo model mund të mos jetë i aftë të njohë mirë të gjitha strukturat e ndryshme.

1.2 ROLI I PARASHIKIMIT INTELIGJENT NË POLITIKËBËRJEN EKONOMIKE DHE INSTITUCIONALE

Parashikimi i zhvillimeve ekonomike nuk përfaqëson thjesht një ushtrim statistik apo një proces mekanik të ekstrapolimit të të dhënave historike në të ardhmen. Në kontekstin modern të politikëbërjes ekonomike dhe institucionale, parashikimi inteligjent shërben si një mjet strategjik që ndihmon aktorët vendimmarrës të kuptojnë dinamikat e sistemeve komplekse, të identifikojnë tendenca të fshehura dhe të vlerësojnë skenarë të mundshëm zhvillimi.

Ndryshe nga analizat tradicionale përshkruese, modelet inteligjente të parashikimit synojnë të kapin marrëdhënie lineare dhe jolineare që nuk janë gjithmonë të dukshme përmes metodave klasike, duke e zhvendosur fokusin nga përshkrimi i së kaluarës drejt mbështetjes aktive të vendimeve për të ardhmen.

Një nga funksionet kryesore të parashikimit inteligjent është reduktimi i pasigurisë ekonomike. Ekonomitë moderne karakterizohen nga paqëndrueshmëri strukturore, ndikime të forta të faktorëve të jashtëm dhe ndërveprime komplekse midis variablave makroekonomikë, financiarë dhe socialë. Në këtë mjedis, pasiguria përbën një nga pengesat kryesore për planifikimin afatmesëm dhe afatgjatë. Modelet parashikuese, veçanërisht ato hibride si ARIMA-ANN, kontribuojnë në uljen e kësaj pasigurie duke ofruar vlerësime probabilitike dhe parashikime më të qëndrueshme, të cilat ndihmojnë institucionet të marrin vendime më të informuara mbi politikën monetare, fiskale, arsimore apo institucionale. Edhe pse pasiguria nuk mund të eliminohet plotësisht, ajo mund të menaxhohet në mënyrë më efektive përmes përdorimit të modeleve inteligjente.

Përdorimi i parashikimit inteligjent është veçanërisht i rëndësishëm në banka qendrore dhe institucione publike, ku vendimmarrja ndikon drejtpërdrejt stabilitetin ekonomik dhe financiar. Bankat qendrore përdorin parashikimet për të orientuar politikën monetare, për të vlerësuar presionet inflacioniste, luhatjet e kursit të këmbimit dhe reagimin e tregjeve financiare ndaj ndërhyrjeve institucionale. Në mënyrë të ngjashme, institucionet arsimore dhe universitetet përballen me nevojën për të parashikuar trende të tilla si numri i studentëve, performanca akademike, motivimi i stafit dhe kërkesat për burime financiare e njerëzore. Integrimi i modeleve inteligjente në këto institucione ndihmon në planifikimin më racional të burimeve, përmirësimin e eficiencës institucionale dhe rritjen e cilësisë së shërbimeve të ofruara.

Në këtë kuadër, modeli hibrid ARIMA-ANN nuk duhet parë thjesht si një model statistik apo algoritëm teknik, por si një instrument mbështetës për vendimmarrje. Kombinimi i strukturës interpretuese të ARIMA-s me fleksibilitetin jolinear të rrjeteve neurale artificiale i mundëson këtij modeli të ofrojë parashikime më të sakta dhe më të qëndrueshme në situata reale, ku të dhënat janë shpesh të paqëndrueshme dhe të ndikuara nga faktorë të shumtë. Roli i ARIMA-ANN nuk është të zëvendësojë vendimmarrësin, por ta pajisë atë me informacion analitik të avancuar, duke krijuar një urë midis analizës sasiore dhe politikëbërjes ekonomike e institucionale

1.3 OBJEKTIVAT DHE PYETJET KËRKIMORE

Objektivi themelor i këtij disertacioni është ndërtimi dhe testimi i një teknike të re hibride për modelimin dhe parashikimin e serive kohore, duke kombinuar fuqinë shpjeguese të modeleve tradicionale statistikore si ARIMA me fleksibilitetin dhe aftësinë për të përpunuar marrëdhënie komplekse të rrjeteve neurale artificiale (ANN).

Në këtë drejtim, një prej qëllimeve kryesore është përdorimi i kësaj qasjeje të kombinuar për të analizuar dhe parashikuar me saktësi katër seri kohore të rëndësishme për realitetin shqiptar: kursin e këmbimit Euro/Lek, çmimin ditor të Bitcoin-it, rezultatet e provimeve të maturës shtetërore dhe nivelin e motivimit të lektorëve në fakultetin e inxhinierisë. Këto seri përfaqësojnë fusha kyçe si ekonomia, tregjet financiare dhe arsimit, duke u bërë objekte të përshtatshme për testimin e modelit të propozuar. Objektiva të tjerë përfshijnë ndërtimin e një teknike që mund të zbatohet praktikisht në hartimin e politikave fiskale dhe monetare përmes rritjes së saktësisë së parashikimeve, studimin dhe krahasimin e zbatimeve aktuale të metodave sasimore dhe inteligjente në literaturë, si dhe identifikimin e një modeli optimal që tejkalon performancën e qasjeve ekzistuese.

Në funksion të këtyre objektivave, janë ngritur tre pyetje kërkimore.

Pyetja kërkimore 1: Ofron modeli hibrid ARIMA-ANN një saktësi më të lartë të parashikimit krahasuar me modelet individuale ARIMA dhe ANN në analizën e serive kohore ekonomike dhe sociale në Shqipëri?

Hipoteza 1 : Modeli hibrid arrin rezultate më të sakta dhe më të qëndrueshme në të gjitha rastet krahasuar me modelet e izoluara, për shkak të ndërthurjes së komponentëve linearë dhe jolinearë të serisë.

Pyetja kërkimore 2: Si ndikon përdorimi i teknikave hibride në përmirësimin e parashikimit të performancës arsimore, konkretisht në rezultatet e maturës shtetërore dhe në vlerësimin e motivimit akademik të stafit universitar?

Hipoteza 2: Modelet hibride janë në gjendje të identifikojnë më saktë prirjet e fshehura dhe jolineare në të dhënat arsimore, duke prodhuar parashikime më të besueshme për politikën e arsimit.

Pyetja kërkimore 2: Cilat janë përfitimet praktike që sjell modeli i zhvilluar për hartuesit e politikave fiskale dhe monetare, veçanërisht në parashikimin e indikatorëve të stabilitetit makroekonomik?

Hipoteza 3 : Modeli i zhvilluar ARIMA-ANN mund të përdoret si një mjet mbështetës për parashikime strategjike afatshkurtra dhe afatgjata, duke kontribuar në përmirësimin e planeve të politikës ekonomike dhe menaxhimit të tregjeve në Shqipëri.

Për të arritur objektivat e përcaktuara dhe për t'iu përgjigjur pyetjeve kërkimore të këtij studimi, është ndërtuar një metodologji e kombinuar që integron teknikat tradicionale statistikore me ato të inteligjencës artificiale. Qasja metodologjike bazohet në katër shtylla kryesore. Së pari, është kryer një *analizë e hollësishme e problemit*, ku janë identifikuar karakteristikat e serive kohore të përzgjedhura, burimet e të dhënave dhe natyra e tyre statistikore. Të dhënat e përdorura përfshijnë kursin e këmbimit Euro/Lek, çmimin ditor të Bitcoin-it, rezultatet e provimeve të maturës shtetërore dhe motivimin

e lektorëve në fakultetin e inxhinierisë. Këto seri kohore janë marrë nga burime të besueshme dhe zyrtare, si INSTAT, Banka e Shqipërisë, Coin Market Cap dhe Ministria e Arsimit.

Së dyti, në fazën e modelimit, janë aplikuar *dy qasje të ndryshme metodologjike*. Qasja e parë përfaqësohet nga përdorimi i modelit ARIMA (AutoRegressive Integrated Moving Average), i cili është i përshtatshëm për seritë kohore lineare dhe me strukturë sezonale ose trenduese. Kjo qasje shërben si bazë për krahasim dhe si pjesë e modelit hibrid. Qasja e dytë përfshin *modelet e inteligjencës artificiale*, konkretisht rrjetet neurale artificiale (ANN), të cilat kanë aftësinë për të identifikuar marrëdhënie komplekse dhe jolineare në të dhëna. ANN trajnohen me të dhëna historike dhe përdoren për të kapur informacionin e mbetur që nuk shpjegohet nga modelet tradicionale.

Së treti, është zhvilluar një *model hibrid ARIMA-ANN*, i cili kombinon rezultatet e dy metodave më sipër në një strukturë të vetme. Kjo qasje synon të kapë elementët linearë përmes ARIMA dhe të trajtojë komponentët jolinearë përmes ANN, duke prodhuar parashikime më të sakta dhe të qëndrueshme. Për zbatimin e kësaj metode, janë ndërtuar algoritmet përkatëse të trajnimit dhe janë përpunuar seritë kohore për secilën variabël.

Së fundi, është realizuar një *vlerësim i performancës së modeleve* përmes treguesve standardë si RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), MPE (Mean Percentage Error) dhe koeficienti U i Theil-it. Këta tregues kanë shërbyer për të krahasuar saktësinë dhe qëndrueshmërinë e parashikimeve të modelit ARIMA, modelit ANN dhe modelit të integruar ARIMA-ANN.

Metodologjia e balancuar ndërmjet teorisë statistikore dhe praktikës së inteligjencës artificiale ka synuar jo vetëm të testojë efikasitetin e një modeli të ri, por edhe të kontribuojë në fushën e vendimmarrjes ekonomike dhe arsimore me aplikime konkrete dhe të transferueshme në institucione të ndryshme.

1.4 KUFIZIMET E STUDIMIT

Çdo kërkim shkencor, pavarësisht rigorozitetit metodologjik dhe saktësisë së analizës, përballlet me kufizime që duhet të njihen dhe adresohen në mënyrë të qartë dhe të ndershme. Edhe ky studim nuk bën përjashtim. Një nga kufizimet kryesore lidhet me përdorimin e një numri të kufizuar serish kohore (katër raste konkrete), të përzgjedhura në funksion të rëndësisë së tyre ekonomike dhe sociale në Shqipëri.

Edhe pse këto seri janë përfaqësuese dhe të ndryshme në natyrë (financiare, arsimore dhe institucionale), rezultatet e nxjerra nuk mund të përgjithësohen automatikisht për të gjitha llojet e serive kohore, sidomos ato që karakterizohen nga mungesa të dhënash, ndërprerje apo struktura shumëdimensionale.

Një kufizim tjetër lidhet me cilësinë, frekuencën dhe kohëzgjatjen e të dhënave. Edhe pse të dhënat janë marrë nga burime të besueshme si INSTAT, Banka e Shqipërisë, Coin Market Cap dhe Ministria e Arsimit, disa seri kohore nuk kanë mbulim të gjatë kohor ose përmbajnë mungesa të pjesshme, të cilat mund të ndikojnë në saktësinë e modelimit. Në disa raste, mungesa e variablave shpjegues të detajuar ka kufizuar përdorimin e modeleve më të avancuara të analizës multivariate ose të modeleve strukturorë.

Në aspektin teknik, ndër kufizimet e tjera të këtij studimi mund të përmendet konfigurimi i rrjetit neural artificial, i cili kërkon një përshtatje shumë të kujdesshme të parametrave të trajnimit, arkitekturës së rrjetit dhe numrit të shtresave të fshehura. Kjo kërkon një ekspertizë të specializuar dhe një sërë testimesh, çka e bën modelin të ndjeshëm ndaj overfitting apo underfitting, në varësi të natyrës së të dhënave.

Për më tepër, modeli hibrid ARIMA-ANN, ndonëse ofron përmirësime të ndjeshme në saktësi, kërkon kohë dhe burime për ndërtimin dhe testimin e tij, duke qenë më kompleks në raport me modelet e thjeshta tradicionale. Kjo ndërlikueshmëri teknike mund të kufizojë zbatimin e modelit në institucione që nuk kanë infrastrukturë teknologjike ose burime njerëzore të trajnuara për përdorimin e teknikave të inteligjencës artificiale.

Fokusi i studimit është vendosur në kontekstin shqiptar, i cili ka specifika të veçanta kulturore, institucionale dhe ekonomike. Kjo mund të kufizojë transferueshmërinë e rezultateve në vende të tjera me struktura më të avancuara të tregjeve ose me sisteme të tjera arsimore dhe financiare. Megjithatë, ky përqendrim lokal përbën një vlerë të shtuar për zhvillimin e kërkimit të aplikueshëm dhe praktik në realitetin shqiptar, duke hapur rrugë për studime krahasimore në të ardhmen.

1.5 PËRMBLEDHJA E TEZËS

Ky studim është ndarë në shtatë kapituj kryesorë, të cilët ndërtojnë gradualisht kuadrin teorik, metodologjik dhe zbatues të modelimit dhe parashikimit të serive kohore përmes qasjeve klasike, inteligjente dhe hibride.

Kapitulli i parë paraqet bazën teorike dhe justifikimin shkencor për ndërtimin e një modeli hibrid ARIMA-ANN për parashikimin e serive kohore në kontekstin shqiptar. Fillimisht diskutohet rëndësia e modelimit të serive kohore në fushat ekonomike, financiare dhe arsimore, duke krahasuar qasjet lineare tradicionale me ato jolineare të inteligjencës artificiale. Përcaktohen objektivat dhe pyetjet kërkimore të studimit, së bashku me motivimin për zgjedhjen e katër serive kohore të rëndësishme për analizë.

Më pas, përshkruhet metodologjia e kombinuar dhe mënyra e testimit të modeleve, duke vlerësuar saktësinë përmes treguesve statistikë. Në fund, analizohen kufizimet kryesore të studimit dhe vendoset theksi mbi rëndësinë e këtij kërkimi për përmirësimin e vendimmarrjes në Shqipëri.

Kapitulli i dytë paraqet një pasqyrë të gjerë të literaturës që lidhet me modelimin e serive kohore. Vëmendje e veçantë i kushtohet zhvillimeve më të fundit në përdorimin e teknikave të inteligjencës artificiale për qëllime parashikimi. Fokusohet te metodat tradicionale statistikore, ku theksi vihet mbi modelin ARIMA - një prej qasjeve më të përdorura në analizën e serive kohore lineare. Edhe pse këto metoda janë të konsoliduara, ato trajtohen shkurtimisht për të ndërtuar më pas kontrastin me qasjet më moderne. Janë përmbledhur konceptet themelore që lidhen me identifikimin, përshtatjen dhe vlerësimin e modeleve ARIMA. Gjithashtu, analizohen qasje hibride të propozuara më parë në literatura, duke shqyrtuar efikasitetin e tyre në trajtimin e serive kohore me sjellje të ndërlikuar. Kjo pjesë shërben si themel për vendosjen e kontekstit teorik të punimit.

Kapitulli i tretë, fokusohet në rrjetet neurale artificiale si një qasje moderne dhe jolineare për modelimin e serive kohore. Ai përshkruan strukturën e rrjeteve si Perceptroni dhe MLP⁸ (perceptron me shumë shtresa), duke theksuar aftësinë e tyre për të mësuar nga të dhëna historike dhe për të kapur modele të ndërlikuara që modelet tradicionale nuk arrijnë t'i përshkruajnë. Shpjegohen hapat e trajnimit të rrjetit, ndarja e të dhënave në bashkësi trajnimi dhe testimi, dhe problematika e mbivendosjes (overfitting). Përmes shembujve praktikë, tregohet si rrjetet NAR⁹ (model autoregresiv jolinear) janë zbatuar për parashikim dhe çfarë parametrash ndikojnë në saktësinë e modelit. Kapitulli krijon bazën teorike për integrimin e këtyre rrjeteve në një qasje hibride me modelet ARIMA në kapitujt pasues.

Kapitulli i katërt trajton zhvillimin e modeleve klasike (ARIMA) dhe moderne (ANN) për modelimin dhe parashikimin e serive kohore, duke theksuar nevojën për qasje hibride për shkak të kompleksitetit të të dhënave reale. Diskutohet motivimi për kombinimin e modeleve lineare dhe jolineare, dhe prezantohen tre arkitektura hibride: seri-lineare-jolineare, seri-jolineare-lineare dhe paralele. Jepet një përshkrim i detajuar i secilës arkitekturë, së bashku me ilustrime dhe formula që shpjegojnë mënyrën e funksionimit. Shtjellohen punime të ndryshme nga literatura që kanë vërtetuar efikasitetin e qasjeve hibride krahasuar me modelet e përdorura veçmas. Në fund, propozohet një model i ri hibrid ARIMA-ANN që shfrytëzon të gjithë komponentët e nxjerrë nga ARIMA si input për rrjetin neural, duke tejkalluar kufizimet e supozimeve klasike. (K.Zela,L.Saliaj,D.Hyka,(2023)).

Kapitulli i pestë përshkruan metodologjinë e ndërtimit dhe testimit të modelit hibrid ARIMA-ANN për katër seri kohore të ndryshme me rëndësi për ekonominë, financën dhe arsimin në Shqipëri. Ai paraqet përzgjedhjen e rasteve studimore, burimet zyrtare të të dhënave, si dhe hapat e ndjekur për ndërtimin e modeleve individuale ARIMA dhe ANN. Për çdo rast specifik kursi Euro/Lek, çmimi i Bitcoin-it, rezultatet e maturës dhe motivimi i lektorëve është ndjekur një trajtim metodologjik i diferencuar dhe i

⁸ Multi-Layer Perceptron

⁹ Nonlinear Autoregressive

përshtatur me natyrën e të dhënave. Më pas, është ndërtuar modeli hibrid për secilin rast dhe është vlerësuar performanca përmes treguesve si RMSE, MAE dhe MAPE. Kapitulli përfundon me krahasimin vizual dhe numerik të modeleve, duke konfirmuar përparësinë e modelit hibrid në ofrimin e parashikimeve më të sakta dhe të qëndrueshme.

Kapitulli i gjashtë paraqet rezultatet e marra nga aplikimi i modeleve ARIMA, ANN dhe modelit të propozuar hibrid ARIMA-ANN mbi katër seri kohore me rëndësi kombëtare. Për çdo rast, raportohen treguesit e performancës RMSE, MAE, MPE¹⁰ (gabimi mesatar përqindor) dhe MAPE, duke e bërë të mundur krahasimin objektiv të saktësisë ndërmjet modeleve. Rezultatet tregojnë se modeli hibrid ka përmirësuar ndjeshëm performancën në të gjitha rastet, sidomos në uljen e gabimeve relative dhe absolute. Janë ndërtuar tabela dhe grafikë krahasues që vizualizojnë performancën e çdo modeli kundrejt serisë origjinale, duke dhënë një panoramë të qartë të efikasitetit të qasjes së integruar. Në fund, interpretohet ndikimi praktik i parashikimeve më të sakta për vendimmarrjen në fusha si edukimi, ekonomia monetare dhe tregjet dixhitale.

Kapitulli i shtatë përmbledh përfundimet kryesore të arritura nga studimi, duke theksuar se modeli hibrid ARIMA-ANN ofron parashikime më të sakta se modelet e ndërtuara veçmas. U konstatua se kombinimi i komponentëve linearë me ata jolinearë përmes një arkitekture të përshtatur rrit ndjeshëm kapacitetin parashikues për seri kohore komplekse dhe të paqëndrueshme. Studimi konfirmon vlefshmërinë e qasjes hibride në aplikime të ndryshme si financat, tregjet dixhitale, arsimi dhe psikologjia institucionale. Rekomandohet zgjerimi i analizës në seri më të gjata dhe përdorimi i metodave të avancuara për optimizimin e hiperparametrave të rrjetit. Gjithashtu, sugjerohet aplikimi i qasjeve hibride në modele të tjera si LSTM¹¹ (rrjetet nervor me memorie afatgjatë dhe afatshkurtër) dhe GRU¹² (rrjetet nervor rekursiv me njësi të portuara), për të përmirësuar më tej aftësitë parashikuese në mjedise reale. Areekul, *et. al.*, (2010)

¹⁰ Mean Percentage Error

¹¹ Long Short-Term Memory

¹² Gated Recurrent Unit

KAPITULLI 2

RISHIKIMI I LITERATURËS

Zbatimi i metodave për të parashikuar dhe për të ndihmuar vendimmarrjen në investime është mëse e domosdoshme në shumë fusha. Parashikimi i serive kohore është një nga zbatimet më të rëndësishme të metodave sasiore, ku grumbullohen dhe analizohen vëzhgime të kaluara të së njëjtës ndryshore, për të zhvilluar një model që përshkruan marrëdhënien themelore të tyre (Aryal & Yao-Wu, 2003). Kjo qasje modelimi është veçanërisht e dobishme kur në dispozicion janë pak informacione mbi procesin themelor që gjeneron të dhëna ose kur nuk ka një model shpjegues të kënaqshëm që lidh ndryshoret e parashikimit me ndryshore të tjera shpjeguese (Zhang, 2003).

Procedurat parashikuese përfshijnë teknika dhe modele të ndryshme. Teknika si, “mesatarja rrëshqitëse” (moving average), “ecja e rastit” (random walk) dhe modelet e trendeve, “sheshimi eksponencial” (exponential smoothing), modelet e regresit të shumëfishtë (multivariate), modelet e vektorëve autoregresivë, modelet e bashkëintegruara dhe rastësore, metodat e bazuara në rrjetat neurale, sistemet eksperte, sistemet fuzzy ose teknikat e nxjerrjes së të dhënave dhe njohurive, janë metoda tipike që përdoren në parashikimin e serive kohore (Ragulskis & Lukoseviciute, 2009).

Seritë kohore mund të shfaqen lineare, jolineare ose të kombinuara. Modelimi i tyre kryhet sipas natyrës së strukturës së serive kohore, duke krijuar kështu modelet lineare ose jolineare. Modelet lineare shpjegojnë lidhjen midis ndryshoreve me anë të mjeteve të korrelacionit linear. Tek modelet jolineare, lidhja midis ndryshoreve nuk mund të shpjegohet me anë të korrelacioneve lineare. Të dhënat e vëzhguara të ky model janë krijuar nga një funksion, i cili është një kombinim jolinear i parametrave të tij dhe varet nga një ose më shumë ndryshore të pavarura. Shpesh, është e vështirë të dallohet natyra e strukturës së serive. Ato mund të jenë linearisht të pastra, jo lineare ose mund të kenë të kombinuara të dyja strukturat. Në rastin e fundit analiza e serive kohore dhe ndërtimi i modeleve për parashikim vështirësohet.

Nga ana tjetër, analiza e serive kohore gjendet në dy lloj formash: analizë themelore dhe analizë teknike. Analiza themelore përqëndrohet në politikat e përgjithshme, pasqyrat financiare të kompanive, informacionin e tregut. Ndërkohë që, analiza teknike përdor të dhënat historike për të ndërtuar një model, që mund të kryejë parashikime për vlerat e ardhshme të një serie. Analiza teknike ose univariate analizon vetëm një ndryshore, atë të serisë kohore në studim dhe nuk merr parasysh marrëdhënien e tij me faktorët që e ndikojnë (Lee, 2000). Sipas disa studimeve, kjo lloj analize rezulton më e mirë në parashikim. Në studimin e tij Athanasopoulos (2010) arriti në përfundimin se: “modelimi i serive kohore me një ndryshore siguron një parashikim më të saktë se modelet me ndryshore shpjeguese”. Të dyja metodat synojnë të zgjidhin të njëjtin problem, por analiza themelore studion shkakun e lëvizjes së tregut, ndërkohë që,

teknikët studiojnë efektin (Lee & Murphy, 1999). Studimet kanë treguar se, të dyja teknikat kanë të metat dhe përfitimet e tyre.

Përfitimi më i madh i analizës themelore është aftësia për të kuptuar dinamikën e tregut. Ndërsa analiza teknike nuk përdor asnjë të dhënë ekonomike, vetëm mjete që janë lehtësisht të kuptueshme në krahasim me treguesit themelor. Analizat teknike janë elastike, në gjendje të përshtaten me çdo mjet parashikimi dhe sasi kohe, janë të afta të njohin trendet dhe ngjarjet ekstreme të tregut, të cilat zbulohen dhe shpjegohen nga analizat themelore. Studiuesit akademikë janë më tepër të interesuar në analizën teknike, në gjetjen e njohurive matematike. Kjo lloj analize do të përdoret edhe në këtë studim.

2.1 KËRKIMET NË PARASHIKIMIN E SERIVE KOHORE ME MODELIN ARIMA

Modelet ARIMA janë një nga modelet më të përdorura të serive kohore. Popullariteti i modeleve ARIMA vjen si rrjedhojë e karakteristikave të tyre statistikore ashtu si edhe metodologjisë mjaft të njohur Box-Jenkins (Box & Jenkins, 1970) në procesin e ndërtimit të modelit. Për më tepër, thuhet se, shumë modele të ndryshme mund të modelohen nga modelet ARIMA. Studime mbi analizën e serive kohore janë zhvilluar në vendin tonë dhe shumica prej tyre janë trajtuar me metodat statistikore (Sinaj & Tushaj, 2011; Gjika, 2014). Edhe pse modelet ARIMA janë elastike, në kuptimin që mund të modelojnë tipe të ndryshme të serive kohore, të parashikojnë saktë në një periudhë të shkurtër kohore dhe paraqesin thjeshtësi zbatimi, e meta më e madhe e tyre është lineariteti.

Modelet ARIMA supozojnë se, vlerat e ardhshme të një serie kohore kanë një marrëdhënie lineare me vlerat e kaluara dhe me zhurmën e bardhë, kështu që, përafrimet nga modelet ARIMA nuk janë të përshtatshme për problemet komplekse jolineare. Shumë studiues kanë treguar se, problemet e botës reale shpesh janë jolineare (Zhang, 2003). Këto prova kanë inkurajuar kërkues akademikë dhe njerëz të biznesit që të zhvillojnë modele parashikuese më praktike sesa modelet lineare (Khashei & Bijari, 2011).

2.1.1 KËRKIMET NË PARASHIKIMIN E SERIVE KOHORE ME MODELETPARAMETRIKE

Shumë klasa modelesh jolineare parametrike dhe joparametrike janë propozuar në literatura të ndryshme në mënyrë që të kapërcehen kufizimet e modeleve lineare dhe të merren parasysh strukturat jolineare të problemeve ve reale. Ndër modelet më të njohura parametrike janë: modeli bilinear (Granger & Anderson, 1978), modeli autoregresiv i pragut (TAR¹³) (Tong, 1983), modeli heteroskedastik autoregresiv i kushtëzuar

¹³ Threshold AutoRegressive

(ARCH¹⁴) (Engle, 1982), modeli i përgjithësuar heteroskedastik autoregresiv i kushtëzuar (GARCH) (Bollerslev, 1986), dinamikat kaotike (Hsieh, 1988) dhe modeli autoregresiv vet-eksitues i pragut (Chappell et. al., 1996).

Ndërkohë që, këto modele janë efikase për një situatë të caktuar, performojnë dobët për raste të tjera. Arsyeja është se, modelet e lartpërmendura janë zhvilluar për struktura specifike jolineare dhe nuk janë të afta për të modeluar tipe të tjera jolineariteti në seritë kohore (Khashei & Bijari, 2011).

2.1.2 KËRKIMET NË PARASHIKIMIN E SERIVE KOHORE ME MODELIN ANN

Rrjetat neurale artificiale (ANN) janë një tip modelesh jolineare joparametrike inteligjente, që janë propozuar dhe provuar për parashikim. Mendohet se, i pari që ka zbatuar rrjetin neural në seritë kohore financiare është White (1989). Ai përdori një rrjet me dy shtresa për serinë e aksioneve të IBM. Një metodë e mirë jolineare duhet të jetë në gjendje të kapë mjaftueshëm dukuritë jolineare të të dhënave.

Rrjeti neural është një nga këto metoda. Ai është në gjendje të modelojë në mënyrë elastike një numër të madh modelesh jolineare dhe jo vetëm, mund të përafrojë një numër të madh funksionesh me një shkallë të lartë saktësie. Fuqia e tij vjen si rrjedhojë e paralelizmit, tipar kryesor i rrjetit neural.

Groot & Würtz (1992) prezantuan një analizë të detajuar të parashikimit të serive kohore univariate, duke përdorur rrjetat neurale të drejtëpërdrejta për dy seri kohore jolineare. Ata ishin ndër të parët që provuan se, rrjetat neurale janë në gjendje të parashikojnë më mirë se modelet tradicionale ARIMA.

Poli & Jones (1994) propozuan një model rrjeti neural stokastik të bazuar në filtrin Kalman për parashikimin e serive kohore jolineare, i cili vazhdoi të përdorej dhe më pas për rezultatet e kënaqshme që jepte.

Zhang (2003) studioi rolin e konstantes α_1 dhe variancës në fushën e parashikimit të serive kohore me ANN. Për më tepër, pati dhe shumë konkurse në rang të gjerë në fushën e parashikimit (Balkin & Ord, 2000; Gershenfeld & Weigend, 1994), ku sugjeroheshin se, rrjetat neurale mund të jenë një mjet shtesë shumë i dobishëm në paketat e parashikimit të serive kohore. Duke marrë parasysh përparësitë e rrjetave neurale (Panda & Narasimhan, 2007), kjo metodologji ka tërhequr vazhdimisht vëmendjen e studiuesve në parashikimin e serive kohore.

Rrjetat neurale artificiale janë gjetur të jenë një pretendent i vlefshëm për modelet tradicionale të serive (Chen et. al., 2007; Kumar & Thenmozhi, 2012). Leandro & Santos (2007) hodhi hipotezën se, modelet jolineare të Perceptron- it me shumë shtresa

¹⁴ AutoRegressive Conditional Heteroskedasticity

janë të afta të sjellin një parashikim më të saktë sesa modelet lineare tradicionale. Rezultatet treguan se, ANN- të performojnë më mirë sesa modelet lineare ARIMA (Khashei & Bijari, 2011). Po ashtu, kanë rezultuar eficiente rrjeta të tjerë neural të propozuar për të parashikuar seri kohore sezonale (Hamzacebi, 2008; Kihoro, et. al, 2004).

Model tjetër parashikimi inteligjent joparametrik është modeli “Fqinji më i afërt” (Nearest Neighbor). Megjithatë, rezultatet e disa kërkuesve që kanë studiuar parashikimin e serive kohore sugjerojnë se, këto modele nuk mund të përmirësojnë saktësinë e parashikimit aq sa modelet e tjera joparametrike të serive kohore (Gvaladze, 2015).

Kohët e fundit, edhe në vendin tonë, janë zhvilluar disa punime me bazë modelin rrjet neural, të cilat kanë provuar eficiencën e përdorimit të këtyre teknikave inteligjente për ndërtimin e modeleve parashikuese afatshkurtra (Vika, 2016; Dara, 2015).

Çmimi ditor i Bitcoin-it është një fenomen shumë i rëndësishëm për studiuesit e tregjeve financiare, investitorët dhe rregullatorët ekonomikë. Tregjet e kriptomonedhave, me Bitcoin-in si përfaqësuesin më të njohur, karakterizohen nga një paqëndrueshmëri ekstreme, shpeshherë më e lartë se ajo e instrumenteve tradicionale financiare, gjë që ka sfiduar vazhdimisht parashikueshmërinë klasike (Kristoufek, 2013; Lahmiri & Bekiros, 2019). Në literaturë, është provuar se luhatshmëria e çmimit të Bitcoin-it nuk mund të përshkruhet plotësisht vetëm nga modelet lineare statistikore si ARIMA, pasi kjo seri kohore përfshin elementë të theksuar jolinearë, struktura kaotike dhe shpërndarje të trashë të bishtave (heavy tails). Për këtë arsye, vitet e fundit është rritur ndjeshëm zbatimi i rrjeteve neurale artificiale dhe teknikave të tjera të inteligjencës artificiale për të modeluar dhe parashikuar këtë seri komplekse.

McNally et al. (2018) përdorën rrjete LSTM (Long Short-Term Memory) për të parashikuar çmimin e Bitcoin-it dhe treguan se kjo qasje mund të kapë më mirë modelet e gjata jolineare sesa modelet tradicionale si ARIMA. Mallqui & Fernandes (2019) analizuan katër teknika inteligjente rrjetet perceptron me shumë shtresa (MLP), rrjetet LSTM, pemët e vendimit dhe vektorët mbështetës dhe zbuluan se rrjetet LSTM dhe MLP prodhuan performancën më të mirë të parashikimit për periudha të ndryshme kohore, sidomos në tregjet e paqëndrueshme. Sasia dhe granulariteti i të dhënave të disponueshme, si çmimet ditore, volumet e tregtimit, sentimentit i tregut dhe indikatorët teknikë, mundësojnë një zbatim shumë efikas të teknikave inteligjente jo vetëm në rritjen e saktësisë së parashikimit, por edhe në identifikimin e tipareve kyçe që shpesh janë të fshehura për modelet lineare.

Zbatimi i rrjeteve neurale NAR (Nonlinear AutoRegressive) është diskutuar edhe për seritë e çmimeve të Bitcoin-it, megjithëse literatura mbetet ende në fazë zhvillimi krahasuar me aplikimet për seritë e aksioneve ose normave të interesit. Zhang et al. (2020) prezantuan modele hibride ku rrjeti NAR u testua në variante me cikël të hapur

dhe të mbyllur, duke treguar se rrjeti me cikël të hapur ofron parashikime më të sakta për shkak të fleksibilitetit më të madh në njohjen e modeleve të reja, ndërsa ai me cikël të mbyllur ka tendencë të bëhet i mbingarkuar me gabime kumulative. Kjo përkon me natyrën e zhurmshme të çmimit të Bitcoin-it ku spekulimet, lajmet e paparashikuara dhe ndërhyrjet e tregut mund të krijojnë devijime të papritura. Një tipar dallues i literaturës mbi Bitcoin-in është edhe përdorimi i inputeve shitesë, si indikatorët teknikë (p.sh. mesataret lëvizëse, RSI, Bollinger Bands), të dhënat nga rrjetet sociale (Twitter sentiment), apo edhe modelet e përbëra me optimizues evolutiv. Lahmiri & Bekiros (2019) theksojnë se qasjet hibride që kombinojnë ARIMA me ANN ose LSTM mund të ofrojnë performancë më të mirë, duke përfituar nga avantazhet e modeleve lineare për trendet dhe sezonalitetin dhe të rrjeteve neurale për komponentët jolinearë dhe anomalitë.

Nga ana praktike, zbatimi i metodave inteligjente për çmimin e Bitcoin-it nuk ka vetëm vlerë akademike, por ndihmon gjithashtu tregtarët e automatizuar (trading bots) dhe investitorët institucionale që të krijojnë strategji të përparuar të menaxhimit të rrezikut. Kjo është një veti që vjen nga aftësia e rrjeteve për të mësuar në mënyrë të vazhdueshme, duke u përshtatur me të dhëna të reja dhe duke përmirësuar vetë modelet me kalimin e kohës. Shumë studiues sugjerojnë se ndërtimi i sistemeve të automatizuara të tregtimit duhet të përfshijë kombinimin e qasjeve klasike dhe atyre inteligjente për të marrë maksimumin nga të dy botët. Në përmbledhje, literatura tregon qartë se çmimi ditor i Bitcoin-it mbetet një nga sfidat më komplekse për parashikimin e saktë për shkak të natyrës së tij shumë jolineare dhe të paqëndrueshme. Për këtë arsye, përdorimi i modeleve hibride ARIMA-ANN, NAR dhe LSTM është një qasje që po merr gjithnjë e më shumë vëmendje dhe që kërkon optimizim të vazhdueshëm për të arritur rezultate më të besueshme.

Kursi i këmbimit ndikohet nga shumë faktorë të ndërlidhur ekonomikë, politikë dhe socialë. Ndërveprimi i këtyre faktorëve është mjaft kompleks. Ndaj, parashikimi i kësaj serie konsiderohet një problem i vështirë. Janë zhvilluar një numër i madh studimesh me metoda të ndryshme për modelimin dhe parashikimin e serisë së kursit të këmbimit. Sërish ajo mbetet një detyrë sfiduese. Yao & Tan (2000) krijuan rrjetin neural me të dhëna të serisë kohore dhe tregues të thjeshtë si mesatarja rrëshqitëse për të njohur ndryshimet e kursit të këmbimit të dollarit amerikan kundrejt pesë monedhave të huaja. Autorët treguan se, pa përdorur faktorë të jashtëm mund të kryhen parashikime të vlefshme me anë të rrjetit neural. Lloji i rrjetave neurale jo lineare autoregresive (NAR), që janë përdorur dhe në këtë punim, janë propozuar në 2002 (Allende, et.al, 2002).

Në këtë punim u tregua se, rrjeti NAR performonte më mirë se modelet e tjera jolineare statistikore. Dunis et. al., (2011) për parashikimin e kursit të këmbimit zbatuan arkitektura të ndryshme të rrjetave neurale dhe krahasuan performancën e tyre me modelet ARIMA. Rezultatet treguan se, rrjetat performojnë më mirë se modeli tradicional dhe kur rrjetat integrohen me filtrat parashikimi bëhet akoma dhe më eficient.

Huang et. al., (2004) në studimin e tyre provuan se, disa faktorë të projektimit të rrjetit neural, ndikojnë ndjeshëm në saktësinë e parashikimit të kursit të këmbimit. Gjithashtu provuan rëndësinë e analizave statistikore paraprake në përcaktimin e disa parametrave të rrjetit neural si, madhësia e bashkësive të të dhënave, frekuenca etj. Një përfundim tjetër i rëndësishëm ishte integrimi i ANN me teknika të tjera për të optimizuar parashikimin. Një studim i kryer në Shqipëri (Vika, 2016) ka zhvilluar ndërtimin e një sistemi inteligjent për analizën dhe parashikimin e kursit të këmbimit nëpërmjet Rrjetave Neurale. Në krahasimin midis performancës së parashikimit të ANN me metodën tradicionale ARIMA, rrjeti neural dominon.

Rezultatet e provimeve të maturës shtetërore janë një fenomen me rëndësi të madhe për arsimtarët, politikat arsimore, prindërit dhe vetë nxënësit si përfitues direkt të sistemit arsimor. Në nivel ndërkombëtar, vlerësimi dhe parashikimi i performancës në teste standarde është konsideruar prej kohësh një temë kyçe për sigurimin e cilësisë, planifikimin arsimor dhe përdorimin e burimeve publike në mënyrë më efektive (Hanushek & Woessmann, 2011). Ndërkohë, Shqipëria, si vend në tranzicion, ka bërë hapa të rëndësishëm në ndërtimin e sistemeve të standardizuara të maturës shtetërore që nga fillimi i viteve 2000, por analizat shkencore të thelluara për trendet dhe faktorët ndikues kanë mbetur kryesisht në nivelin deskriptiv ose raportues vjetor nga Ministria e Arsimit.

Në literaturën ndërkombëtare, shumë autorë (Kotsiantis et al., 2004; Minaei-Bidgoli et al., 2003) kanë demonstruar se përdorimi i rrjeteve neurale artificiale (ANN) dhe algoritmeve të tjerë inteligjentë, si Pemët e Vendimit (Decision Trees) ose Modelet e Regresionit Logjistik të avancuar, mund të ofrojë parashikime shumë më të sakta për suksesin e nxënësve sesa qasjet tradicionale lineare. Këto modele inteligjente kanë avantazhin që kapin marrëdhënie komplekse jolineare midis të dhënave hyrëse, nota paraprake, frekuentimi në shkollë, statusi socio-ekonomik, niveli arsimor i prindërve, kushtet e shkollës, përfshirja në aktivitete jashtëshkollore dhe performancës përfundimtare në provime.

Një tipar kyç që theksohet në studime të tilla është rëndësia e cilësisë dhe granularitetit të të dhënave hyrëse (Huang et al., 2004). Për shembull, përdorimi i historikut të notave nga klasat IX–XII, raportet e mungesave, pjesëmarrja në aktivitete mësimore shtesë, dhe të dhënat socio-ekonomike të nxënësit mund të ndihmojnë në ndërtimin e një profili më gjithëpërfshirës për secilin maturant. Në shumë sisteme arsimore, këto modele janë përdorur për të krijuar sisteme paralajmëruese (Early Warning Systems) që sinjalizojnë nxënësit me risk të lartë të mospërfitimit dhe ndihmojnë shkollat të ndërhyjnë në kohë.

Në Shqipëri, ndërtimi i një modeli të tillë me rrjete neurale ose qasje hibride (p.sh., ARIMA-ANN për trendin dhe luhatjet ndër vite) do të ishte i pari në llojin e vet. Ai do të mundësonte që Ministria e Arsimit dhe Drejtoritë Arsimore të kuptonin më mirë se ku duhet të përqendrojnë resurset: shkollat me performancë të ulët, qarqet me probleme të përsëritura, apo faktorët e caktuar që ndikojnë motivimin dhe përgatitjen e nxënësve.

Për më tepër, ky model mund të lidhet me Sistemet e Menaxhimit të Informacionit Arsimor (EMIS) për të pasur të dhëna në kohë reale. Aftësia e rrjeteve neurale për të mësuar dhe për të përzgjedhur vetë tiparet më relevante, pa supozuar shpërndarje statistike të caktuara, i bën këto teknika veçanërisht të vlefshme për një mjedis arsimor dinamik dhe të ndërlikuar si ai shqiptar. Një instrument i tillë mund të bëhet pjesë e një politike më të madhe për sigurimin e cilësisë dhe përgatitjen për reformat që synojnë përmirësimin e vazhdueshëm të standardeve kombëtare të arsimit parauniversitar.

Motivimi i lektorëve dhe stafit akademik në fakultetet e inxhinierisë ka një ndikim të drejtpërdrejtë në cilësinë e mësimdhënies, prodhimin shkencor dhe përgatitjen e brezave të rinj të inxhinierëve dhe profesionistëve të teknologjisë. Sipas literaturës ndërkombëtare, faktorët që ndikojnë në motivimin e stafit akademik përfshijnë një gamë të gjerë elementësh si: siguria në punë, mundësitë për zhvillim profesional dhe trajnime, kushtet e punës, autonomia në planifikimin e mësimin, shpërblimet financiare dhe jo-financiare, dhe kultura institucionale (Herzberg, 1987; Oshagbemi, 2000; Saiti, 2007). Në universitetet bashkëkohore, menaxhimi i motivimit nuk shihet më vetëm si përgjegjësi administrative, por si pjesë integrale e sistemeve të menaxhimit të burimeve njerëzore (HRM) dhe sistemeve të menaxhimit të performancës.

Në kontekstin shqiptar, hulumtimet që lidhen me këtë temë janë ende në fazë fillestare dhe shpesh fokusohen në sondazhe të izoluara që matin nivelin e kënaqësisë në punë, pa e lidhur atë me qasje sasiore, modele inteligjente apo sisteme mbështetëse të vendimmarrjes. Përpjekja e disa autorëve shqiptarë, si Katerina Zela et al., për të propozuar Sisteme të Menaxhimit të Informacionit (MIS) për grumbullimin dhe analizimin e vazhdueshëm të të dhënave mbi motivimin, është një hap i rëndësishëm drejt modernizimit të kësaj fushe.

Në literaturën ndërkombëtare janë propozuar edhe modele ku rrjetet neurale përdoren për të analizuar faktorë të ndryshëm të motivimit, duke marrë në konsideratë ndërveprimet e ndërlikuara mes variablave të ndryshëm. Për shembull, mbështetja institucionale, mundësitë për bashkëpunim ndërkombëtar, niveli i ngarkesës administrative, klima kolegjiale, mundësitë për financim të projekteve kërkimore dhe shpërblimi moral, janë faktorë që, në shumicën e rasteve, nuk kanë lidhje lineare, por ndërthuren në mënyrë komplekse. Rrjetet neurale kanë avantazhin që mund të mësojnë këto marrëdhënie pa pasur nevojë për supozime paraprake, duke krijuar një pamje më të saktë të situatës motivuese në fakultet (Saiti, 2007).

Në Shqipëri, zbatimi i një modeli të tillë do të përfaqësonte një praktikë inovative që mund të përmirësojë jo vetëm mirëqenien e stafit akademik, por edhe cilësinë e mësimdhënies dhe produktivitetin shkencor. Një instrument i dixhitalizuar mund të përfshijë sondazhe të strukturuar, sisteme vlerësimi të performancës, tregues të integruar të ngarkesës mësimore dhe kërkimore, si dhe module feedback-u anonim që mund të analizohen automatikisht nga një rrjet ANN.

Një qasje e tillë mund të ndihmojë menaxhmentin e fakulteteve të identifikojnë tendencat e brendshme, të parashikojnë riskun e braktisjes së profesionit akademik dhe të marrin masa të personalizuara për të përmirësuar motivimin dhe performancën. Një model i tillë do ta vendoste Shqipërinë më afër praktikave më të mira të universiteteve europiane që tashmë kanë filluar të lidhin teknologjitë e Inteligjencës Artificiale me menaxhimin strategjik të burimeve njerëzore. Megjithëse rrjetat neurale artificiale kanë aftësinë e parashikimit të saktë, performanca e tyre në disa situata specifike është kontradiktore. Në literaturë, shumë artikuj kanë trajtuar krahasimin e ANN-ve me metodat tradicionale. Në kundërshtim me shumë studime që kanë provuar se, ANN-të janë më të mira se modelet lineare tradicionale dhe se parashikimi i tyre është në mënyrë të konsiderueshme dhe të vazhdueshme më i saktë, disa studime të tjera kanë raportuar rezultate të kundërta.

Denton (1995) me të dhënat e gjeneruara nga kushte të ndryshme eksperimentale tregoi se, në kushte ideale me gjithë supozimet e regreseve ka pak diferencë në parashikim midis ANN-ve dhe regresit, vetëm në kushte më pak ideale ANN-të performojnë më mirë. Ward & Foster (1996) gjeti se, ANN-të janë shumë më të dobëta sesa regressi linear dhe se metoda e “sheshimit eksponencial”. Hann & Steurer (1996) bëjnë krahasime midis rrjetave neurale dhe modelit linear në parashikimin e kursit të këmbimit. Ata raportojnë se, nëse përdoren të dhëna mujore, rrjetat neurale nuk tregojnë shumë përmirësime krahasuar me modelet lineare. Khashei & Bijari, (2011) krahasojnë performancën e modeleve lineare me rrjetat neurale. Rezultatet e tyre tregojnë se, modelet autoregresive lineare mund t’ia kalojnë në performancë rrjetave neurale në disa raste. Shumica e kërkuesve të tjerë bëjnë gjithashtu krahasime midis ANN-ve dhe metodave përkatëse tradicionale në zbatimet e tyre të veçanta.

Tang & Fishwick (1993) përpiqen t’i përgjigjen pyetjes: në cilat kushte ANN-të parashikuese mund të performojnë më mirë se metodat lineare parashikuese të serive kohore si modelet Box-Jenkins. Disa kërkues besojnë se, në disa situata specifike ANN-të performojnë më keq se modelet lineare statistikore, arsyeja mund të jetë se, të dhënat janë lineare pa shumë çrregullime, kështu që, nuk mund të pritët që ANN-t të jenë më mirë se modelet lineare për marrëdhëniet lineare (Zhang et. al., 2003). Megjithatë, për arsye të ndryshme, përdorimi i ANN-ve për të modeluar problemet lineare ka nxjerrë rezultate të ndryshme dhe si rrjedhojë nuk këshillohet të përdoren ANN-të për çdo tip të dhënash pa e analizuar si fillim serinë.

2.1.3 KËRKIMET NË PARASHIKIMIN E SERIVE KOHORE ME MODELET HIBRIDE

Kombinimi i parashikimeve është një çështje e trajtuar gjerësisht kohët e fundit. Shumë studiues për të reduktuar gabimin e parashikimit kombinojnë teknika të ndryshme, që variojnë në nivel kompleksiteti dhe efikasiteti. Literatura e modeleve hibride për parashikimin e serive kohore është zgjeruar shumë që nga puna e hershme e Reid (1968) dhe Bates & Granger (1969).

Clemen (1989) solli një përmbledhje dhe bibliografi në këtë fushë. Ai arriti në përfundimin se, saktësia e parashikimit mund të përmirësohet ndjeshëm përmes kombinimit të disa parashikimeve individuale. Sipas këtij studimi, kombinimi i parashikimeve duhet të bëhet pjesë e praktikës së parashikimit. Për të arritur këtë, praktikuesit duhet të inkurajohen të kombinojnë parashikimet dhe duhet të vendosen në dispozicion të tyre softuer për të prodhuar parashikime të kombinuara me lehtësi. Janë një sërë studimesh që kanë propozuar metodologji të ndryshme me bazë rrjetin neural për analizën e serive kohore. Pelikan et. al., (1992) dhe Ginzburg & Horn (1994) propozuan të kombinonin disa rrjeta neurale të drejtëpërdrejta për të përmirësuar saktësinë e parashikimit të serive kohore. Goh et. al., (2003) përdorën një tërësi rrjetash Elman për parashikimin e serive.

Armano et. al., (2005) prezantuan një qasje hibride që integroi rrjetin neural artificial me algoritmat gjenetike për parashikimin e tregut të aksioneve. Rezultatet e këtyre studimeve kanë treguar se, është e mundur të parashikosh saktë duke reduktuar pasigurinë e lidhur me parashikimin e serive kohore pa përdorur asnjë të dhënë ekzogjene, vetëm vlerat historike, duke kërkuar kështu vetëm disa sekonda. Një rast tjetër hibridizimi inteligjent jepet në studimin e Kutbatsky (2011) të cilët propozuan një qasje të re me dy faza që kombinon teknikën efektive të transformimit Hilbert-Huang dhe teknologjinë parashikuese të rrjetit neural artificial. Një teknikë që rezultoi sërish efiçiente në parashikimin e serisë kohore.

2.1.4 KËRKIMET NË PARASHIKIMIN E SERIVE KOHORE ME MODELIN ARIMA-ANN

Një nga komponentet përbërëse të metodologjisë që përdoret në këtë studim, sikurse është theksuar tashmë, është rrjeti neural, komponentja tjetër paraqitet nga metoda sasiore tradicionale ARIMA. Ka disa shembuj në literaturat ekzistente që kombinojnë modelet parashikuese të rrjetit neural me teknikat tradicionale të parashikimit të serive kohore, kryesisht ARIMA.

Wedding & Cios (1996) propozuan një metodologji hibride duke përdorur rrjetat me simetri rrethore (RBF) dhe modelet Box-Jenkins ARIMA për të parashikuar disa seri kohore univariate. Analiza e tyre vërtetoi se, modeli hibrid është i aftë të japë parashikime më të mira. Luxhoj et. al., (1996) prezantuan një qasje hibride me modelet ekonometrike dhe ANN për parashikim. Kjo qasje rezultoi me performancë të mirë parashikimi. Këto ishin propozimet e para në metodat hibride ARIMA-ANN.

Megjithatë metodologjitë e plota hibride ARIMA-ANN janë krijuar vetëm vitet e fundit. Tseng et. al., (2002) propozuan përdorimin e një modeli hibrid të quajtur SARIMABP që kombinonte modelin SARIMA dhe modelin e rrjetit neural me prapapërhapje për të parashikuar të dhënat e serive kohore. Pai dhe Lin (2005) propozuan një metodologji hibride për të shfrytëzuar përparësitë e modeleve sasiore dhe inteligjente për parashikimin e serive kohore.

Modeli hibrid rezultoi elastik, në gjendje të njihte tiparet e fshehta të serive dhe në krahasim me modelet e përdorura veçmas performanca e tij shfaqti vlera shumë të ulta të treguesve matës. Zeng, et. al., (2008) krijuan modelin hibrid ARIMA me ANN për parashikimin aftashkurtër të serive. Rezultatet e eksperimentit vërtetuan se, modeli i propozuar hibrid përmirëson në mënyrë të dukshme saktësinë e parashikimit. Chen & Wang (2007) ndërtuan një model kombinimi që përfshin modelin SARIMA dhe metodën inteligjente për parashikimin e serive kohore sezonale. Khashei et. al., (2009) prezantuan një model hibrid nga kombinimi i ARIMA me teknika të inteligjencës artificiale si, rrjeti neural dhe logjika Fuzzy për parashikimin e tregut financiar.

Kjo teknikë hibride arriti të përmirësonte parashikimin e ARIMA dhe të rrjetit neural në sajë të aftësisë së logjikës Fuzzy për trajtimin e të dhënave të pasigurta dhe të paqarta. Ata propozuan një model hibrid për të kapërcyer kufizimet e të dhënave të rrjetave neurale dhe për të nxjerrë një model më të saktë parashikimi, veçanërisht në kushte të dhënash jo të plota. Yu, et. al., (2014) në studimin e tyre propozuan një model hibrid që kombinon modelin sezonal ARIMA dhe rrjetin neural jolinear autoregresiv (NARNN) për të parashikuar duke përdorur vëzhgimet retrospektive të marra nga Sistemi Informativ i Kinës për Kontrollin dhe Parandalimin e Sëmundjeve. Po ashtu Wongsathan & Seedadan (2016) për të përmirësuar performancën e parashikimit të ARIMA dhe ANN, përdorën modelin hibrid ARIMA-ANN. Rezultatet eksperimentale treguan se, modeli hibrid mbizotëronte më së miri mbi ANN dhe ARIMA të përdorura veçmas.

Hamilton et. al., (2017) me modelin hibrid të tyre mundësuan vlerësimin më të mirë të parametrave dhe përmirësimin e parashikimit afatshkurtër në situata, ku ekziston një pasiguri e madhe në parametrat e modelit. Samia, et. al., (2012) ndërtuan modelin e hibridizuar ARIMA-ANN. Modeli i kombinuar mund të përdoret si një sistem efikas i parashikimit dhe paralajmërimit të hershëm për sigurimin e informacionit. Në një studim tjetër, (Sallehuddin & Shamsuddin, 2008) metoda statistikore GRA¹⁵ dhe ANN janë kombinuar si teknika për gjetjen e modelit më të mirë. GRA përdoret për të zgjedhur hyrjet e rëndësishme dhe për t'i renditur sipas prioritetit. Ndryshe nga metodat tradicionale hibride, zbatohet fillimisht ANN dhe më pas ARIMA.

Modeli i propozuar tejkaloi saktësinë e parashikimeve të modeleve të tjera. Yu et. al., (2005) propozuan një model parashikimi jolinear që integronte autoregresionin linear të përgjithësuar (GLAR) me rrjetat neurale artificiale në mënyrë që të merrej parashikim i saktë në tregun e këmbimit valutor. Areekul, et. al., (2010) për problemin e parashikimit të serive kohore në Australi ndërtuan një model hibrid ARIMA-ANN. Rezultatet empirike të saj treguan një saktësi të lartë parashikimi krahasuar me teknikat ARIMA dhe ANN veçmas.

¹⁵ Grey Relational Analysis

Teknikat hibride që shpërbëjnë një seri kohore në formën e vet lineare dhe jolineare janë një nga modelet hibride më popullore. Përmirësimi i performancës së parashikimit financiar duke përdorur arkitektura të ndryshme të kombinimit të modeleve ARIMA dhe ANN është zhvilluar nga Hajirahimi & Khashei (2016). Kohët e fundit, këto modele kanë rezultuar të jenë më të suksesshme se modelet lineare ARIMA dhe modelet jolineare, rrjetat me shumë shtresa. Ato sugjerohen nga literaturat të përdoren bashkarisht në mënyrë që të njohin format e ndryshme të marrëdhënies të seritë kohore.

2.2 KONCEPTET BAZË TË PARASHIKIMIT TË SERIVE KOHORE

2.2.1 SERITË KOHORE

Seri kohore quhet një bashkësi vrojtimesh të një ndryshoreje të caktuar të matura në momente ose intervale kohe të njëpasnjëshme për një periudhë kohe të caktuar. Matematikisht një seri kohore përfaqëson një realizim të vetëm të një procesi rasti të indeksuar në kohë $Z(t)$, ku $t = 0, 1, 2, \dots$

Një seri kohore mund të jetë e vazhdueshme ose diskrete. Në një seri të vazhdueshme vëzhgimet maten në çdo çast të kohës, ndërsa një seri kohore diskrete përmban vrojtimit e matura në pikat diskrete të kohës. Normat e lindshmërisë, norma e interesit për lekun si dhe kursi i këmbimit midis dy monedhave të ndryshme mund të përfaqësojë seritë kohore diskrete. Këto seri janë me frekuenca mujore.

Një seri kohore diskrete mund të supozohet se, është matur si një ndryshore e vazhdueshme duke përdorur shkallën e vërtetësisë të matjes (Hipel & McLeod, 1994). Për më tepër një seri kohore e vazhdueshme mund të transformohet lehtë në një seri diskrete nga bashkimi i të dhënave së bashku mbi një interval të caktuar kohor. Çdo seri kohore mund të përmbajë të gjitha ose disa nga komponentet të cilat janë: Trendi T , Cikli C , Sezonaliteti S dhe Komponentja jo e rregullt I . Këto komponente mund të kombinohen si prodhim, ose mund të paraqiten në trajtën e shumës:

$$Y_t = T \cdot C \cdot S \cdot I \text{ ose } Y_t = T + C + S + I$$

Trendi është prirja që ka seria kohore në periudha afatgjata. Pra, me kalimin e kohës vlerat mund të kenë prirje për t'u rritur ose për t'u zvogëluar. Një model sezonal ekziston kur seria ndikohet nga faktorë sezonal (tri muaj, një muaj, një javë, një ditë). Sezonaliteti është një periudhë e njohur fikse (Hyndman & Athanasopoulos, 2013).

Modeli ciklik ekziston kur të dhënat shfaqin ngritje dhe ulje që nuk janë të një periudhe të caktuar. Kohëzgjatja e këtyre lëkundjeve, në përgjithësi, është të paktën dy vjet. Shumë njerëz e ngatërrojnë sjelljen ciklike me sjelljen sezonale, dy modele krejt të ndryshme. Nëse luhatjet nuk ndodhin në periudhë fikse, ato janë ciklike dhe nëse ndodhin në periudha fikse atëherë modeli është sezonal.

Modelet e serive kohore janë një klasë e modeleve me anë të të cilave parashikohen vlerat e serisë duke përdorur vetëm informacionin e vlerave të kaluara dhe aktuale të saj, ndoshta vlerat aktuale dhe të shkuara të termit të gabimit. Modelet e serive kohore janë teorike duke nënkuptuar se, ndërtimi dhe përdorimi i tyre nuk bazohet në ndonjë model teorik themelor të sjelljes së një ndryshoreje (Brooks, 2014). Një klasë e rëndësishme e modeleve të serive kohore është familja e modeleve ARIMA, të cilat zakonisht i referohen Box dhe Jenkins (1970).

2.2.2 STACIONARITETI

Një seri kohore $\{Z_t, t = 0, \pm 1, \pm 2, \dots\}$, quhet stacionare e fortë (rigorozisht stacionare) nëse për çdo numer të plotë h , shpërndarja e saj probabilitare $(Z_{t1}, Z_{t2}, \dots, Z_{tk})$ është e njëjtë me shpërndarjen e serisë së zhvendosur $\{Z_{t+h}, t=0, \pm 1, \pm 2, \dots\}$ për çdo k dhe për çdo zgjedhje t_1, t_2, \dots, t_k .

Le të jetë $\{Z_t\}$ një seri me vlerën e pritur $\mathbb{E}[Z_t^2] < \infty$, funksioni mesatar i serisë Z_t është $\mu_Z(t) = \mathbb{E}[Z(t)]$, kurse funksioni i kovariancës :

$$\gamma_Z(r, s) = \text{Cov}(Z_r, Z_s) = \mathbb{E}[(Z_r - \mu_Z(r))(Z_s - \mu_Z(s))]$$

Seria $\{Z_t\}$ është stacionare e dobët nëse funksioni i mesatares, variaciones dhe i kovariancës janë të pavarur nga koha. Pra,

$E(Z_t)$ – është e pavarur nga koha

$\text{Var}(Z_t)$ – është e pavarur nga koha

$\text{Cov}(Z_t, Z_{t-k})$ – është e pavarur nga koha

Pra, që një seri të jetë stacionare, duhet që pritja matematike, varianca dhe kovarianca të jenë konstante (të mos varen nga koha t). Në mënyrë analitike shkruhet:

$$\mathbb{E}[Z(t)] = \mu, \text{konstante}, \text{Var}(Z_t) = D(Z_t) = \sigma^2, \text{konstante} \quad (2.3)$$

$$\text{Cov}(Z_t, Z_{t-k}) = \gamma_k \text{ për } k = 1, 2, \dots [a]$$

Përkufizimi i mësipërm i stacionaritetit ka të bëjë me atë që njihet si stacionaritet i dobët ose stacionaritet në kuptimin e gjerë. Në përgjithësi në praktikë nuk përdoret kovarianca, por koeficientët e korrelacionit të cilët ndihmojnë të ndërtohet funksioni i autokorrelacionit (me paraqitje grafike korrelogramen), i cili përcaktohet nga barazimi i mëposhtëm:

$$\rho(k) = \frac{\text{cov}(Z_t, Z_{t-k})}{\sqrt{\text{VAR}(Z_t)}\sqrt{\text{VAR}(Z_{t-k})}}$$

Korrelograma mat shkallën e ndikimit të vlerave të mëparshme të serisë mbi ato të tashme dhe të ardhshme korrelograma ndërtohet vetëm për $k > 0$ sepse nga vetitë e koeficientit të korrelacionit është $\rho(k) = \rho(-k)$.

Në praktikë shumë seri kohore janë jostacionare, pra e thënë ndryshe karakteristikat e procesit stokastik ndryshojnë në lidhje me kohën. Mirëpo këto seri mund të transformohen në seri stacionare duke bërë diferencime të rendeve të ndryshme. Me përkufizim, seria kohore X_t është jostacionare homogjene e rendit d , në qoftë se seria $Y_t = \Delta^d X_t$ është stacionare. Ku Δ^d tregon diferencimin e rendit d dhe seria quhet stacionare e rendit d ose integrale e rendit d , $i(d)$. Një mënyrë e thjeshtë për të gjykuar në lidhje me stacionaritetin e një serie kohore është dhe funksioni i autokorrelacionit, ACF. ACF me lag k përcaktohet nga ρ_k dhe jepet nga formula e mëposhtme:

$$\rho_k = \text{corr}(Z_t, Z_{t-k}) = \frac{\text{cov}(Z_t, Z_{t-k})}{\text{VAR}(Z_t)} \quad \text{për } k = 0, 1, 2, \dots$$

Nga kushtet 1 dhe 2 të stacionaritetit në formulën [a] rrjedh se, nuk ka rëndësi momenti t , i njehsimit të korrelacionit të mësipërm, por vetëm “distanca” kohore k , si dhe $\text{Var}(Z_t) = \text{Var}(Z_{t-k})$, gjithashtu vihet re se, $\rho(0) = \text{corr}(Z_t, Z_t) = 1$ për çdo seri kohore. Për një zgjedhje $\{Z_1, Z_2, \dots, Z_n\}$ nga një seri kohore vlerësimi i ACF-së është:

$$\rho(k) = \frac{\gamma_k}{\gamma_0}$$

ku:

$$\gamma_k = \frac{\sum(Z_t - \bar{Z})(Z_{t-k} - \bar{Z})}{n}; \quad \gamma_0 = \frac{\sum(Z_t - \bar{Z})^2}{n}$$

Grafiku i funksionit $\rho(k)$ kundrejt vlerave të k -së quhet *korrelogram*. Korrelograma mat shkallën e ndikimit të vlerave të mëparshme të serisë mbi ato të tashme dhe të ardhshme. Korrelograma ndërtohet vetëm për $k > 0$ sepse nga vetitë e koeficientëve të korrelacionit është $\rho(-k) = \rho(k)$. Krahas ACF jepet dhe përkufizimi i PACF, funksioni i autokorrelacionit të pjesshëm, i cili njehson korrelacionin ndërmjet Z_{t-h} dhe Z_t , pas largimit të efektit të Z_s - ve për $s = t - h + 1, t - h + 2, \dots, t - 1$.

2.2.3 TESTI I RRËNJËVE UNITARE

Dickey dhe Fuller (1979, 1981) hartuan një procedurë për të testur për stacionaritetin e serive kohore, testin DF. Vështirësia kryesore e testit të tyre është se, testimi për jostacionaritet është i njëvlershëm me testimin për ekzistencën e një rrënje unitare. Kështu, testi bazohet në modelin AR¹⁶(1) të thjeshtë:

$$Y_t = \rho Y_{t-1} + u_t$$

Nevojitet të tregohet se, $\rho = 1$ dhe kjo do të tregojë se, ekzistojnë rrënjët unitare.

¹⁶ AutoRegressive

Hipotezat e ngritura janë: $H_0: \rho = 1$ (rrënjë unitare, seri jostacionare) dhe hipoteza alternative $H_a: \rho < 1$ (seri stacionare).

Te modeli i mësipërm zbritet anë për anë termi me një vonesë kohore dhe përftohet:

$$Y_t - Y_{t-1} = \rho Y_{t-1} - Y_{t-1} + u_t$$

$$\Delta Y_t = (\rho - 1)Y_{t-1} + u_t$$

$$\Delta Y_t = \delta Y_{t-1} + u_t \text{ ku } \delta = \rho - 1$$

Tashmë hipotezat e ngritura janë:

$$H_0: \delta = 0 \text{ (rrënjë unitare, jostacionare)} \text{ dhe } H_a: \delta < 0 \text{ (stacionare)}$$

Nëse $\delta = 0$, atëherë seria ndjek një bredhje rasti dhe për rrjedhojë nuk është stacionare.

Dickey dhe Fuller (1979) propozuan dy ekuacione regresi alternative, të cilat ndihmojnë në zbulimin e rrënjëve unitare. Në ekuacionin e parë shtohet intercepti në bredhjen e rastit, ekuacioni është:

$$\Delta Y_t = \alpha + \delta Y_{t-1} + u_t$$

Sipas Asteriou & Hall (2007), intercepti është shumë i rëndësishëm, sepse ka seri të cilat shfaqin një tendencë të caktuar kur $\delta = 0$, kjo gjë ndodh shpesh për ndryshore makroekonomike.

Rasti i dytë është zgjerim i rastit të parë, ku shtohet në ekuacion dhe trendi. Ekuacioni është:

$$\Delta Y_t = \alpha + \gamma t + \delta Y_{t-1} + u_t$$

Për testimin e hipotezave përdoret statistika student për të tri modelet, kurse vlerat kritike janë llogaritur fillimisht nga Dickey dhe Fuller. Testimi ka të bëjë me faktin nëse $\delta = 0$.

2.2.4 TESTI DICKEY-FULLER I PËRGJITHËSUAR (ADF¹⁷)

Meqenëse termi i gabimit ka shumë raste që nuk është zhurmë e bardhë, atëherë Dickey dhe Fuller zgjeruan procedurën e testimit. Ky ekuacion i ri do të përmbajë dhe terma të serisë së diferencuar me vonesa kohore deri në lag-un p , me qëllim eliminimin e autokorrelacionit të mbetjeve.

¹⁷ Augmented Dickey-Fuller

Gjatësia e vonesës në këto kushte shtesë përcaktohet nga një prej kritereve: AIC¹⁸, SBC¹⁹, ose zakonisht përdoret ajo vlerë e vonesës që nevojitet për t'i kthyer mbetjet në zhurmë të bardhë (pas secilit rast, kontrollohet nëse mbetjet e regresit të ADF-së janë të autokorreluara apo jo përmes testit LM²⁰ dhe jo testit DW²¹).

Tri format e mundshme të testit të ADF jepen nga ekuacionet :

$$\Delta Y_t = \delta Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + u_t$$

$$\Delta Y_t = \alpha + \delta Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + u_t$$

$$\Delta Y_t = \alpha + \gamma t + \delta Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + u_t$$

Për testimin e hipotezës së ngritur përdoret statistika studentit, ndërsa zona kritike është bishti i majtë i shpërndarjes. Pra nëse vlera e vrojtuar e testit studentit është më e madhe se vlera kritike, atëherë hipoteza bazë bie poshtë (vlerat kritike për hipotezën e njëanshme janë njehsuar nga MacKinnon (1991)).

2.2.5 KRITERET E PËRZGJEDHJES SË MODELEVE

Selektimi i modeleve ka si synim të zgjedhë një model statistikor nga një grup modelesh kandidate të dhëna. Këtu mund të përfshihet edhe vet-dizenjimi i modelit në mënyrë të tillë që të dhënat e mbledhura t'i përshtaten modelit të krijuar. Përzgjedhja e modelit konsiderohet si, një problem vendimmarrje, si pasojë e të cilit zgjidhet një problem statistikor në mënyrë që të kryhet një analizë statistikore si, vlerësimi, testimi, intervali i besimit, parashikimi, simulimi e kështu me rradhë.

1. *Kriteri Akaike i Informacionit*

Kriteri Akaike i Informacionit (AIC) është një ndër kriteret më të rëndësishme që përdoret për selektimin e modeleve. Kriteri ofron një matje relative të informacionit të një modeli që përpiqet të përshkruajë realitetin. Kur jepen një grup të dhënash, shumë modele kandidate mund të renditen sipas vlerave të tyre AIC. Pra AIC ofron një kriter për krahasimin e modeleve, për të thënë se cili nga modelet e dhënë është më i mirë. AIC nuk kryen një testim të modelit në kuptimin e zakonshëm duke testuar një hipotezë bazë të ngritur më parë. AIC nuk jep informacion se sa mirë një model i dhënë i përshtatet të dhënave. Pra, nëse të gjithë modelet e dhëna për krahasim nuk përshtaten mirë me të dhënat, AIC nuk e provon këtë gjë. Ai thjesht rendit modelet dhe tregon se,

¹⁸ Akaike Information Criterion

¹⁹ Schwarz Bayesian Criterion

²⁰ Lagrange Multiplier

²¹ Durbin-Watson

cili prej tyre është më i mirë se të tjerët. Në rastin e përgjithshëm kriteri AIC njehsohet nga formula e mëposhtme:

$$AIC = 2k - 2\ln(L)$$

ku, k është numri i ndryshoreve të pavarura të modelit dhe L është vlera e funksionit të përgjasisë maksimale të po këtij modeli.

2. Kriteri Bayesian i Informacionit (BIC²²)

Kriteri Bayesian i Informacionit (BIC) ose ndryshe kriteri Schwarc është një kriter për selektimin e modelit midis një grupi të caktuar modelesh. Ai është i bazuar pjesërisht në funksionin e përgjasisë dhe është i lidhur ngushtë me kriterin Akaike të Informacionit (AIC). Kur përshtaten modelet është e mundur të rritet përgjasia duke shtuar parametrat, por kjo mënyrë e veprimit mund të çojë në gabime të rastit në vend që të japë lidhjen ndërmjet tyre. BIC e zgjidh këtë problem duke futur një term penaliteti për numrin e parametrave në model. Ky penalizim është më i madh në kriterin BIC sesa në AIC. Kriteri BIC është një rezultat asimptotik që vjen nga supozimi se, shpërndarja e të dhënave gjendet në familjen eksponenciale. Formula për kriterin BIC është:

$$BIC = -2\ln L + k\ln(n)$$

3. Algoritmi H-K

Algoritmi H-K është zhvilluar nga Hyndman dhe Kandakhar në 2008. Ky algoritëm integrohet në paketën forecast të softuerit R. Ai është përdorur në gjetjen e modeleve SARIMA²³ për shumë seri kohore ekonomike, si në serinë e inflacionit me frekuencë mujore, në shtetin Turk, nga Saz (2011). Sävås (2013), ishte një tjetër studiues që e përdori algoritmin H-K për modelet parashikuese të inflacionit në Suedi. Për modelimin dhe parashikimin e serive kohore, Manjang (2014) përdori algoritmin H-K në gjetjen e modelit SARIMA. Edhe pse i krijuar kohët e fundit, rastet e zbatimit të algoritmit H-K vijjnë e rriten me shpejtësi.

Në mënyrë ciklike ky algoritëm arrin të gjejë modelin e duhur të serisë kohore, në sajë të krahasimit që u bën kritereve të informacionit AIC, BIC dhe AICc dhe zgjedh atë model që minimizon çdo kriter. Nëse më parë gjetja e modelit të duhur duke krahasuar çdo model të mundshëm të gjeneruar do të kërkonte shumë kohë, tashmë me këtë algoritëm përshpejtohet procesi i përzgjedhjes së modelit. Për të marrë vlerat e kritereve, fillimisht duhet funksioni i vlerësimit, $L(\Psi)$ ku Ψ është vlerësimi maksimal i SARIMA me n parametra dhe madhësi të zgjedhjes T .

$$n = p + q + P + Q + 1$$
$$AIC = -2\log[L(\Psi)] + 2n$$

²² Bayesian Information Criterion

²³ Seasonal AutoRegressive Integrated Moving Average

$$AIC_C = AIC + \frac{2n(n+1)}{T-n+1}$$

$$BIC = -2\log [L(\Psi)] + n\log(T)$$

Më pas vepron në mënyrë ciklike për të zgjedhur modelin që minimizon vlerën e çdo kriteri të mësipërm. Algoritmi fillon me vlerësimin e katër modeleve:

- 1) SARIMA (2, d , 2) x (1, D , 1) s
- 2) SARIMA (0, d , 0) x (0, D , 0) s
- 3) SARIMA (1, d , 0) x (1, D , 0) s
- 4) SARIMA (0, d , 1) x (0, D , 1) s

ku d dhe D janë gjetur më parë dhe përfshihet një konstate në model, nëse $d + D \leq 1$. Më pas përzgjidhet modeli që arrin vlerën më të vogël për kriterin e zgjedhur dhe algoritmi vazhdon me ndryshimin e parametrave si më poshtë:

1. Ndryshon secila nga parametrat p , q , P dhe Q me ± 1 .
2. Ndryshojnë në të njëjtën kohë të dyja parametrat p dhe q me ± 1 .
3. Ndryshojnë në të njëjtën kohë të dyja parametrat P dhe Q me ± 1 .
4. Ndërprit procesin nëse hapat më sipër nuk janë përfshirë, në të kundërt vazhdo.

Algoritmi do të përsëritet deri sa vlera e kriterit të mos ketë më mundësi zvogëlimi. Ndërkohë që funksionon algoritmi, janë disa kufizime që ndiqen në mënyrë që të ketë përshtatje sa më të mirë modeli:

1. Rendi maksimal i p dhe q është pesë.
2. Rendi maksimal i P dhe Q është dy.
3. Refuzohen të gjitha modelet joinverse dhe joshkakësore.
4. Refuzohet modeli nëse shfaqen gabime gjatë përshtatjes së tij në ciklin e optimizimit jolinear.

Pas ekzekutimit me këto kushte, është e sigurtë që algoritmi do të gjejë një model të vlefshëm duke qenë se bashkësia e modeleve është e vogël, modeste dhe të paktën një nga modelet e fillimit do të pranohet.

2.2.6 VLEFSHMËRIA E PARASHIKIMIT

Problemi i matjes së vlefshmërisë së parashikimit të dhënë nga disa metoda të ndryshme ka qenë subjekt që ka tërhequr vëmendjen e shumë studiuesve në fushën e serive kohore. Një diskutim i plotë mbi këtë çështje jepet nga Hyndman dhe Koehler (2016).

Krahasimi midis vlerave të parashikuara dhe të dhënave të vëzhguara japin gabimin e parashikimit dhe masin performancën e çdo metode. Për një analizë sa më të saktë dhe të plotë është e nevojshme të përdoren tregues të ndryshëm statistikor. Ka tri raste sipas të cilave mund të përftohet një parashikim:

1. *Gabimet mesatare*

Nëse vlera e serisë është Y_t dhe parashikimi i saj \hat{Y}_t atëherë gabimi i parashikimit është $u_t = Y_t - \hat{Y}_t$, ndërsa gabimi i parashikimit me h hapa më vonë me një hap përpara është $u_{t+h} = Y_{t+h} - \hat{Y}_{t+h}$.

Madhësitë më të përdorshme:

- Gabimi mesatar absolut:

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |u_t|$$

- Gabimi i mesatares së katrorëve:

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n u_t^2$$

- Gabimi rrënjë katrorë e mesatares së katrorëve:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n u_t^2}$$

Kur krahasohen metodat parashikuese në të njëjtën seri, preferohet të përdoret si madhësi krahasuese MAE duke qenë se është e lehtë për t'u kuptuar dhe njehsuar. Ajo nuk mund të përdoret për të bërë krahasime midis serive, sepse është e pakuptimtë të krahasosh cilësinë në shkallë të ndryshme.

2. *Gabimet përqindje*

- Gabimi përqindje jepet nga:

$$p_t = \frac{u_t}{F_t} \cdot 100 = \frac{Y_t - \hat{Y}_t}{Y_t} \cdot 100$$

Gabimet përqindje kanë përparësi duke qenë se janë të pavarur nga shkalla, nuk kanë një shkallë natyrale. Për këtë arsye përdoren kryesisht për të krahasuar performancën parashikuese midis serive kohore të ndryshme. Treguesi matës që përdoret më shumë është:

- Gabimi në përqindje i mesatares absolute:

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

Ekzistojnë disa parime të cilat ndihmojnë për të vlerësuar modelin më të mirë. Në studimin e tij Armstrong (2001) provoi disa prej tyre, të cilat janë marrë parasysh në këtë punim, si mos-përdorimi i R2 për krahasimin e modeleve, shqyrtimi i të gjitha kriterëve të rëndësishme dhe treguesve të performancës. Sipas studimeve në dekadën e fundit (Armstrong, 2001), MAPE rezultoi treguesi më i përdorur dhe i saktë për matjen e performancës, ku 52% e studiuesve përdornin MAPE dhe vetëm 10% e tyre RMSE-n.

3. Statistika U e Theil-it

Statistika U e Theil-it, (Theil, 1966) një parametër statistikor i njohur ndryshe edhe si koeficienti i pasigurisë ose koeficienti i entropisë, tregon saktësinë e parashikimeve, duke shqyrtuar informacionin e sjellë nga modeli.

Ai mundëson krahasimin e parashikimeve të metodave të ndryshme me atë që quhet parashikimi naiv (një hamendje e thjeshtë parashikimi që bëhet duke mos pasur njohuri specifike, ku parashikohet që vlera e ardhshme do të jetë sa vlera një hap më para saj). Ky parametër matës tregon nëse parashikimet janë të kënaqshme duke marrë parasysh parashikimin naiv.

Ai llogaritet si më poshtë:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left(\frac{\hat{Y}_{t+1} - Y_{t+1}}{Y_t} \right)^2}{\sum_{t=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}}$$

ku, Y_t është e dhëna aktuale në kohën t , \hat{Y}_t është vlera e parashikuar. Nëse $U = 1$, modeli i parashikimit është ekuivalente me modelin e metodës naive. Nëse $U < 1$, modeli i parashikimit është më i mirë se modeli i metodës naive. Nëse $U > 1$, modeli i parashikimit është shumë më i dobët se modeli i metodës naive.

2.3 MODELET LINEARE TË SERIVE KOHORE

Një seri kohore thuhet se, është lineare ose jolineare në varësi të faktit nëse vlera e saj prezente mund të shprehet si një funksion linear ose jolinear i vlerave të mëparshme të

serisë. Të dhënat e serive kohore mund të kenë disa forma dhe të përshkruajnë procese të ndryshme stokastike. Janë dy modele të përdorura gjerësisht në modelimin e serive kohore lineare, modelet autoregresive (AR) (Box & Jenkins, 1970; Lee, 1974; Hipel & McLeod, 1994) dhe modelet e mesatares rrëshqitëse (MA²⁴) (Box & Jenkins, 1970; Hipel & McLeod, 1994). Shumë literatura propozojnë kombimin e këtyre dy modeleve duke krijuar modelin ARMA (Box & Jenkins, 1970; Hipel & McLeod, 1994) dhe modelin ARIMA (Box & Jenkins, 1970; Hipel & McLeod, 1994).

Duke shkuar më tej, në një seri kohore lineare e cila shfaq edhe sezonalitet këshillohet të përdoret në modelim dhe parashikim, modeli SARIMA (Seasonal Autoregressive Integrated Moving Average) (Hamzacebi, 2008; Box & Jenkins, 1970; Hipel, 1994). ARIMA u popullarizua fillimisht si procedure efikase e parashikimit të serive kohore nga Box dhe Jenkins, ndaj këtyre modeleve u referohen shpesh si modelet Box-Jenkins

2.3.1 MODELE AUTOREGRESIVE TË RENDIT p , AR(p)

Një seri kohore quhet autoregresive e rendit p nëse seria shprehet vetëm nga vetja me vonesa kohore deri në lag- un p . Forma e përgjithshme e një modeli AR(p) është:

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + u_t$$

Në rastin e serive kohore është një koncept i ri që quhet operatori i kthimit mbrapa, i cili shënohet me L ²⁵. Operatori L realizon kthimin e serisë me vonesa kohore duke u bazuar te vetitë e mëposhtme:

$$LX_t = X_{t-1} \text{ dhe } L^k X_t = X_{t-k}$$

Duke u mbështetur në operatorin e kthimit mbrapa, mund të rishkruhet modeli AR(p) në trajtën e mëposhtme:

$$(1 - \varphi_1 L - \varphi_2 L^2 - \dots - \varphi_p L^p) X_t = u_t$$

Polinomi në të majtë të barazimit quhet polinom karakteristik i modelit AR. Rendi i modelit AR është sa fuqia e polinomit të vet karakteristik.

2.3.2 MODELET MESATARE RRËSHQITËSE

Një seri kohore quhet mesatare rrëshqitëse e rendit q nëse seria shprehet vetëm nga mbetjet me vonesa kohore deri në lag- un q . Forma e përgjithshme e një modeli MA(q) është:

$$X_t = u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

Modeli MA mund të shkruhet dhe në gjuhën e operatorit të kthimit mbrapa:

²⁴ Moving Average

²⁵ Në literaturat e serisë kohore për operatorin e kthimit mbrapa përdoret simboli B ose L.

$$X_t = (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) u_t$$

Polinomi në të djathtë të barazimit quhet polinom karakteristik i modelit MA. Rendi i modelit MA është sa fuqia e polinomit të vet karakteristik.

2.3.3 MODELET ARMA²⁶(p, q)

Forma e përgjithshme e modelit është:

$$X_t = \beta_0 + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

2.3.4 MODELET ARIMA(p, d, q)

Në modelet ARIMA, d tregon rendin e diferencimit të nevojshëm për kthimin e serisë në një seri stacionare. Veçohet nga kjo klasë modelesh, modeli më i ndeshur ARIMA($p, 1, q$), forma e përgjithshme e të cilit është:

$$\Delta X_t = \beta_0 + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

Këtu, $\Delta X_t = X_t - X_{t-1}$ përfaqëson *diferencimin e rendit të parë*, dhe përdoret për ta kthyer serinë në formë stacionare për analizë dhe parashikim.

2.3.5 MODELET SARIMA(p, d, q)(P, D, Q) s

Merret modeli SARIMA($p, 1, q$)(P, D, Q)¹². Forma e përgjithshme e këtij modeli në gjuhën e operatorit të kthimit mbrapa është:

$$\begin{aligned} & (1 - \Phi_1 L^{12} - \Phi_2 L^{24} - \dots - \Phi_P L^{12P})(1 - L^{12})^D (1 - L)^d (1 - \varphi_1 L - \varphi_2 L^2 - \dots - \varphi_p L^p) X_t \\ & = \\ & = (1 + \Theta_1 L^{12} + \Theta_2 L^{24} + \dots + \Theta_Q L^{12Q})(1 + \theta_1 L + \dots + \theta_q L^q) u_t \end{aligned}$$

ku u_t janë zhurmë e bardhë $u_t \sim WN(0, \sigma^2)$.

Duke ju referuar praktikave më të mira të ndërtimit të modeleve ARIMA, Rau (2005) e ka sintetizuar në katër hapa metodologjinë e përdorur:

1. Kryhet stacionarizimi i serisë. Kjo realizohet nëpërmjet diferencimit të serisë duke nisur me një kohë të caktuar dhe duke vazhduar më tej në arritjen e modelit më të mirë stacionar.
2. Studiohet autokorrelacioni dhe heteroskedasticiteti për të kuptuar nëse vonesat në serinë e stacionarizuar dhe vonesat në gabime duhet të bëhen pjesë e ekuacionit të parashikimit.
3. Ndërtohet modeli i sugjeruar dhe analizohen mbetjet e tij. Kjo arrihet duke studiuar funksionet e autokorrelacioneve (ACF) dhe funksionin e pjesëshëm të

²⁶ AutoRegressive Moving Average

autokorrelacioneve (PACF) të serisë për të parë nëse koeficientët e modelit janë sinjifikantë.

4. Funksionet ACF dhe PACF mund të sugjerojnë shtimin e termave AR dhe MA për të marrë një model me shpjegueshmëri më të lartë.

KAPITULLI 3

RRJETET NEURALE ARTIFICIALE

Sistemet inteligjente kërkojnë modele dhe zbulojnë marrëdhënie në një grup të madh të dhënash. Për modelimin e serive kohore mund të përdoren teknika të cilat kanë në themel të logjikës së tyre aftësinë për të mësuar. Këto teknika trajtohen nga ajo degë e Inteligjencës Artificiale që njihet si Nxënia Automatique (Machine Learning).

3.1 NXËNIA AUTOMATIKE

Nxënia Automatique përfshin mekanizma përshtatës që mundësojnë kompjuterat të mësojnë nga eksperiencia, trajnimet dhe shembujt. Aftësia për të mësuar mund të përmirësojë performancën e një sistemi inteligjent me kalimin e kohës. Mekanizmat e nxënies automatike krijojnë bazën për sistemet përshtatëse (Murphy, 2012).

Ky paragraf trajton nxënien e koncepteve, ose njohurive i cili mund të formulohet si një problem që kërkon në një hapësirë të parapërcaktuar me hipoteza të konsiderueshme për hipotezën që përshtatet më mirë me shembujt e trajnimit. Për të arritur këtë, projektuesi i algoritmit të nxënies në mënyrë implicite përcakton bashkësinë e të gjithë hipotezave që mund të paraqesë dhe mësojë programi (Mitchell, 1997). Në shumë raste ky kërkim mund të organizohet në mënyrë efektive duke përfitur nga një strukturë e natyrshme rastësie që ndodh tek hapësira e hipotezave.

Njerëzit, vazhdimisht, mësojnë koncepte të përgjithshme. Çdo koncept i tillë mund të shihet si përshkrim i disa nënbashkësive të objekteve ose ngjarjeve të dhëna në një bashkësi më të madhe. Në mënyrë alternative, çdo koncept mund të mendohet si një funksion me vlera booleane i përcaktuar në këtë bashkësi të madhe. Krijimi i funksioneve të përgjithshme nga shembujt të caktuar trajnimi është një problem kryesor në procesin e nxënies. Nëse jepet një problem me ndryshore të caktuara, ku secili ka veçoritë e veta, detyra e problemit është që të mësojë të parashikojë vlerat e ardhshme të tyre bazuar në veçoritë aktuale.

Studimi është i fokusuar në algoritma që janë në gjendje të kërkojnë në mënyrë efikënte në fusha shumë të mëdha hipotezash për të gjetur hipotezën që përshtatet më mirë me të dhënat. Vihet re se, megjithëse detyra e nxënies është të përcaktojë një hipotezë H të njëjtë me konceptin target në të gjithë bashkësinë e të dhënave, informacioni i vetëm që ekziston rreth konceptit target është vlera e tij për shembujt e dhënë.

Kështu që, algoritmat e nxënies mund të sigurojnë se, hipoteza dalëse përputhet me konceptin target për të dhënat e trajnuara. Në këtë pjesë problemi do të nxjerrë në mënyrë automatike rregullin e përgjithshëm të njohurive duke dhënë shembujt të caktuar. Kjo detyrë njihet si nxënia e konceptit, ose përafrimi i një funksioni nga shembujt. Nxënia e konceptit: Krijimi i një funksioni nga shembujt e trajnuar të hyrjeve dhe daljeve të tij. Ndryshe quhet edhe 'Arsyetimi Induktiv'.

Arsyetimi induktiv është teoria e njohjes së funksioneve rekursive nga shembujt e dhënë. Në mënyrë formale problemi i arsyetimit induktiv mund të paraqitet si më poshtë: një agjent ka vëzhguar disa të dhëna $D =$

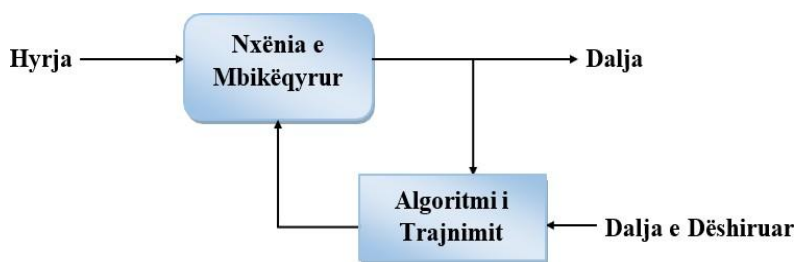
$\{x_1, x_2, \dots, x_n\}$ dhe ka një bashkësi me hipoteza $H = \{h_1, h_2, \dots, h_t\}$ disa prej të cilave mund të jenë modele të mira të procesit të panjohur P , i cili ka gjeneruar D .

Detyra është që të përcaktohet cila hipotezë apo hipoteza nga H ka më shumë mundësi për të ndodhur P . Psh seria kohore $\{x_1, x_2, \dots, x_n\}$ mund të jenë vlerat e aksioneve të bursave dhe H mund të jetë bashkësia e modeleve matematike të çmimeve të aksioneve. Me të njohur cili model ka probabilitetin më të madh për të përshkruar këtë sjellje, do të përdoret ky informacion për të parashikuar vlerat e ardhshme. Megjithëse, mund të pranohet se, të gjitha hipotezat janë konsistente me faktet e vëzhguara në mënyrë intuitive, disa hipoteza kanë më shumë gjasa të ndodhin se disa të tjera. Për të bërë zgjedhjen e një hipoteze nuk duhet të bazohen vetëm në faktet e vëzhguara, por edhe në eksperiencën e mëparshme. Më poshtë do të paraqitet natyra e nxënies induktive me të cilën çdo sistem mund të përgjithësojë suksesshëm nisur nga të dhënat e vëzhguara gjatë trajnimit.

Nxënia induktive klasifikohet në dy kategori: “Nxënia e mbikëqyrur” dhe “Nxënia e pa mbikëqyrur”. Nxënia e mbikëqyrur ndodhë atëherë kur për të mësuar duhet të jenë hyrjet dhe daljet e një problemi (Rumelhart, et. al., 1986), ndërsa nxënia e pa mbikëqyrur ndodh atëherë kur të dhëna janë vetëm hyrjet e problemit (Carpenter & Grossberg, 1988).

3.1.1 NXËNIA E MBIKËQYRUR

Nëse në një algoritëm jepen si të dhëna një bashkësi me hyrje $\{x_1, x_2, \dots, x_n\}$, bashkësia përkatëse e daljeve $\{y_1, y_2, \dots, y_n\}$ atëherë qëllimi i tij është të mësojë për të dhënë si rezultat daljen e duhur kur i jepet një hyrje e re. Në këtë rast, procesi i nxënies quhet i mbikëqyrur. Në këtë algoritëm rrjeti duhet të krijojë vetë çdo model të mundshëm, rregull apo karakteristikë. Për njohjen e modelit rrjeti ndryshon parametrat dhe quhet vet-organizues. Nxënia e mbikëqyrur ngjan me një klasë, ku një mësues verifikon nëse përgjigjet e studentëve janë të sakta ose jo (Rumelhart, et. al., 1986). Dy shembujt më të zakonshëm të nxënies së mbikëqyrur janë klasifikimi dhe regresi numerik. Nëse daljet janë diskrete procesi është duke trajtuar një problem klasifikimi, ose problemin e regresit nëse daljet janë të vazhduara (Becker, 1991).



Figurë 1. Rregulli i nxënies së mbikëqyrur

3.1.2 NXËNIA E PA MBIKËQYRUR

Nëse një algoritmi i jepet si e dhënë vetëm një bashkësi me hyrje $\{x_1, x_2, \dots, x_n\}$ dhe asnjë dalje, atëherë ky është një proces i pa mbikëqyrur i nxënies. Nxënia e pa mbikëqyrur mund të mendohet si krijim modelesh për të dhënat e mësipërme. Nëse teknika e mbikëqyrur ngjason me një klasë, ku ka mësues, teknika e pa mbikëqyrur ngjason me të mësuarin me një videokasetë e cila jep të gjithë materialin e duhur, por pa pasur mundësi që studenti të marrë shpjegime për paqartësitë (Mitchell, 1997).

Dy shembujt më të zakonshëm të nxënies së pa mbikëqyrur janë klasterimi dhe shoqërimi. Hyrjet mund të jenë vektorë të tipeve të ndryshme, objekte, numra të plotë, numra real, stringje, ose objekte më komplekse. Rezultatet marrin vlera që tregojnë një gjendje unike. Për shembull, një algoritmi mund t'i jepen disa vektorë të cilët prezantojnë tipare të jashtme të një personi si, pesha, lartësia, etj dhe daljet përkatëse që marrin një vlerë nga bashkësia $\{femër, mashkull\}$.



Figurë 2. Rregulli i nxënies së pa mbikëqyrur

Rritja e sasisë së të dhënave dhe nevoja për të kryer parashikime të sakta në shumë fusha shkencore dhe zbatuese ka sjellë përdorimin e teknikave të fuqishme dhe efikase që nxjerrin në pah varësinë stokastike ndërmjet të shkuarës dhe së ardhmes. Fusha e parashikimeve është ndikuar që prej viteve 60' nga metoda statistikore lineare si ARIMA. Kohët e fundit modelet e Nxënies Automatikë kanë tërhequr vëmendjen si pretendues serioz ndaj modeleve në fushën e parashikimit. Parashikimi i serive kohore mund të shihet si problem i Nxënies Automatikë. Ky rikonceptim i serisë kohore mundëson integrimin e algoritmave të nxënies në problemin e parashikimit. Teknikat inteligjente më të njohura për parashikimin e serive kohore janë rrjetat neurale artificiale, vektori mbështetës, fqinji më i afërt dhe algoritmat gjenetike.

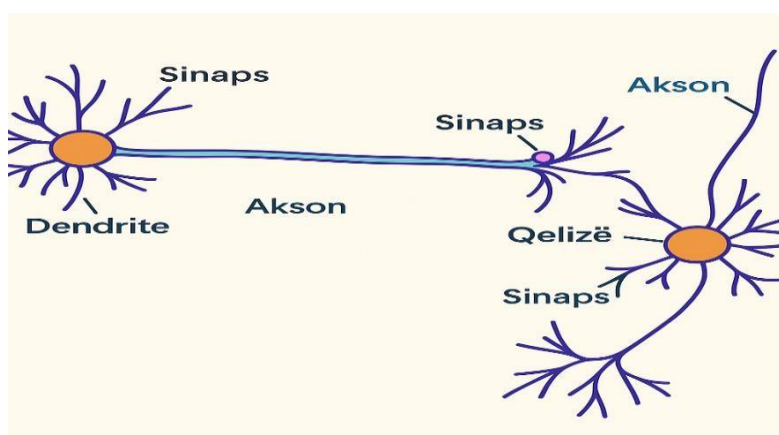
Në këtë punim është zgjedhur për parashikimin e serive kohore nxënia e mbikëqyrur duke qenë se gjatë gjithë kohës së trajnimit modeli optimizohet duke pasur si pikë referimi daljen e dëshiruar. Në mënyrë më specifike është zgjedhur rrjeti neural për nxjerrjen e njohurive në mënyrë induktive, për gjetjen e modelit dhe parashikimin e serive kohore nisur nga shembujt e dhënë. Si pasojë e karakteristikave të jashtëzakonshme të tij në përpunimin e informacionit të tilla si: jolineariteti, paralelizmi, fuqia, toleranca ndaj paqartësive, etj rrjeti neural konsiderohet një metodë shumë popullore.

3.2 RRJETAT NEURALE ARTIFICIALE (ANN)

3.2.1 ÇFARË ËSHTË NJË RRJET NEURAL?

Një rrjet neural mund të përkufizohet si një model i arsyetimit sipas trurit të njeriut. Truri konsiston në një tërësi qelizash neurale të ndërlidhura ose tërësi njësisish përpunuese informacioni, të quajtura neurone. Truri i njeriut ka rreth 86 miliard neurone dhe 100 trilion lidhje ndërmjet tyre ose siç quhen ndryshe sinapse. Duke përdorur shumë neurone njëkohësisht, truri mund të performojë funksionet e tij shumë më shpejtë se sa superkompjuterat në ditët e sotme (Lent, R. ,2025).

Edhe pse neuroni ka një strukturë shumë të thjeshtë, një grupim i elementëve të tillë përbën një fuqi shumë të madhe përpunimi. Një neuron përbëhet nga trupi i qelizës, e quajtur soma, një tërësi fijesh të quajtura dendrite, dhe një fije e vetme e gjatë e quajtur aksoni. Dendritet dalin nga qeliza soma ndërsa aksoni shtrihet nga dendritet e një neuroni drejt somës së një neuroni tjetër. Figura më poshtë tregon në mënyrë skematike rrjetin neural.



Figurë 3. Një rrjet neural biologjik

Sinjalet transmetohen nga një neuron tek tjetri në sajë të reaksioneve elektro-kimike komplekse. Substancat kimike të prodhuara nga sinapsat shkaktojnë një ndryshim në potencialin elektrik të qelizës së trupit. Kur ky potencial arrin vlerën e pragut, një puls elektrik dërgohet nëpërmjet aksonit. Pulsu shpërhapet dhe nëpër sinapse shkakton rritje ose zvogëlim të potencialit të tyre.

Truri ynë mund të konsiderohet si një sistem përpunimi informacioni kompleks, jolinear dhe paralel. Informacioni në të ruhet dhe përpunohet njëkohësisht gjatë gjithë rrjetit dhe jo në vendodhje specifike. Domethënë të dhënat dhe përpunimi i tyre në një rrjet neural janë më tepër global sesa lokal. Gjetja më interesante është se, një rrjet neural shfaq plasticitet. Në përgjigje të modelit të simulimit neuronet demonstronë ndryshime afatgjata në fuqinë e lidhjeve të tyre. Neuronet gjithashtu mund të formojnë lidhje të reja me neurone të tjera. Madje grupe të tëra neuronesh mund të migrojnë nga një vend në tjetrin. Këto mekanizma formojnë bazën e të mësuarit në tru.

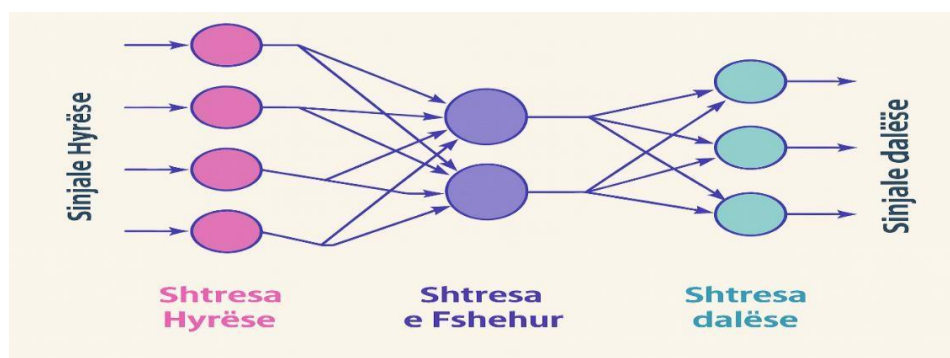
Për shkak të plasticitetit, lidhjet midis neuroneve që çojnë në “përgjigje të sakta” forcohen ndërsa ato që çojnë në “përgjigje të gabuara” dobësohen. Si rezultat: rrjetat neurale kanë aftësi të mësojnë nëpërmjet eksperiencës. Të mësuarit ose nxënia është karakteristikë themelore e rrjetave neurale biologjike. Natyraliteti me të cilin ato mësojnë na çon drejt modelimit të rrjetit neural biologjik në një kompjuter.

Kur rrjetat neurale artificiale ekspozohen ndaj një numri të mjaftueshëm shembujsh, ato mund të përgjithësohen edhe për raste që ende nuk i kanë hasur. Për më tepër, mund të gjejnë dhe përcaktojnë modele, të cilat eksperti nuk arrin t’i njohë. Shembuj problemesh që mund të zgjidhin janë: njohja e karaktereve të shkrimit të dorës, njohja e fjalëve në një fjalim, detektimi i eksplozivë në një aeroport, parashikimi i bursave e tregjeve monetare, etj.

3.2.2 MODELIMI I ANN

Një ANN konsiston në një numër të madh procesorësh të thjeshtë dhe të ndërlidhur, që gjithashtu quhen neurone, të ngjashme me neuronet biologjike. Neuronet lidhen me anë të lidhjeve sinaptike, të cilat mundësojnë kalimin e sinjaleve nga një neuron tek tjetri. Çdo neuron merr një numër të caktuar sinjalesh në hyrje përmes lidhjeve të tij. Sinjali i daljes transmetohet përmes linjës dalëse të neuronit.

Linja dalëse copëzohet në disa degë që transmetojnë të njëjtin sinjal. Degët dalëse përfundojnë në linjat hyrëse të neuroneve të tjera në rrjet. Figura më poshtë paraqet lidhjet e një ANN tipike (Negnevitsky, 2011).



Figurë 4. Arkitektura e rrjetit neural artificial

Si mëson një ANN?

Neuronet lidhen nëpërmjet lidhjeve sinaptike, ku secili ka nga një peshë numerike. Peshat janë mjeti bazë i memories afatgjatë në ANN. Ato shprehin forcën dhe rëndësinë e çdo neuroni hyrës. Një rrjet neural “mëson” përmes rregullimeve të përsëritura të peshave të tij. Siç tregohet edhe në figurë një ANN tipike përbëhet nga një hierarki shtresash dhe neuronet janë vendosur përgjatë këtyre shtresave. Neuronet lidhen me mjedisin e jashtëm nëpërmjet shtresës hyrëse dhe dalëse. Peshat modifikohen për të pasur një sjellje hyrjeje dhe daljeje të rrjetit në të njëjtën linjë me atë të mjedisit.


Çdo neuron është një njësi elementare e përpunimit të informacionit. Për të ndërtuar një ANN, fillimisht duhet të vendoset se sa neurone do të përdoren dhe si do të lidhen këto neurone për të formuar rrjetin. Ndryshe thuhet, duhet të zgjidhet arkitektura e rrjetit. Më pas vendoset cili algoritëm do të përdoret. Në fund trajnohet rrjeti neural të cilit i inicializohen peshat dhe përditësohen këto peshat gjatë trajnimit me një bashkësi shembujsh (Negnevitsky, 2011).

Tabelë 1. Ngjashmëria ndërmjet rrjetit neural biologjik dhe atij artificial

Rrjeti neural biologjik	Rrjeti neural artificial
Bërthamë	Neuron
Dendrite	Hyrje
Akson	Dalje
Sinaps	Pesha

Neuroni, elementi bazë i ndërtimit të një ANN.

Neuroni merr disa sinjale nga lidhjet sinaptike hyrëse, llogarit një nivel aktivizimi dhe e dërgon atë si një sinjal dalje përmes lidhjes së daljes. Sinjali i hyrjes mund të jetë e dhënë e papërpunuar ose dalje e neuroneve të tjera. Sinjali i daljes mund të jetë zgjidhja përfundimtare e një problemi ose një hyrje për neurone të tjera. Figura më poshtë paraqet një neuron tipik.



Figurë 5. Skema e një neuroni

Si e përcakton një neuron daljen e tij?

Warren McCulloch and Walter Pitts (McCulloch & Pitts, 1943) propozuan një ide të thjeshtë që ende sot është baza për shumicën e ANN. Neuroni llogarit shumën e peshuar të sinjaleve të hyrjes dhe krahason rezultatin me vlerën e pragut, θ . Nëse hyrja e peshuar është më e vogël se vlera e pragut, dalja e neuronit është -1. Nëse hyrja e peshuar është më e madhe ose e barabartë me vlerën e pragut, neuroni aktivizohet dhe dalja e tij bëhet +1.

Pra, neuroni përdor funksionin e aktivizimit të mëposhtëm:

$$X = \sum_{i=1}^n x_i w_i \quad Y = \begin{cases} +1 & \text{if } X \geq \theta \\ -1 & \text{if } X < \theta \end{cases}$$


ku, X është hyrja e peshuar e neuronit; x_i është vlera e sinjalit në hyrjen i ; w_i është pesha e hyrjes i ; n është numri i hyrjeve te neuroni; Y është dalja e llogaritur nga neuroni, θ është pragu.

Lloji i funksionit të aktivizimit që është përdorur në këtë rast, është funksioni me prag bipolar. Dalja e llogaritur e një neuroni me funksion me prag bipolar paraqitet:


$$Y = \text{bipolar} \sum_{i=1}^n x_i w_i - \theta$$

Funksionet e aktivizimit


Ekzistojnë shumë tipe funksionesh aktivizimi. Funksioni me prag binar dhe prag bipolar quhen ndryshe funksione prag, karakteristik dhe përdoren kryesisht në problemet e klasifikimit dhe njohje modelesh. Funksioni sigmoid, është një tjetër funksion aktivizimi, i cili transformon hyrjen e peshuar që mund të ketë çdo vlerë nga minus infinit deri në plus infinit në një vlerë nga 0 deri në 1c.




$$y_{\text{binar}} = \begin{cases} +1, & \text{nëse } X \geq 0 \\ 0, & \text{nëse } X < 0 \end{cases}$$



$$y_{\text{bipolar}} = \begin{cases} +1, & \text{nëse } X \geq 0 \\ -1, & \text{nëse } X < 0 \end{cases}$$



$$Y_{\text{sigmoid}} = \frac{1}{1 + e^{-x}}$$



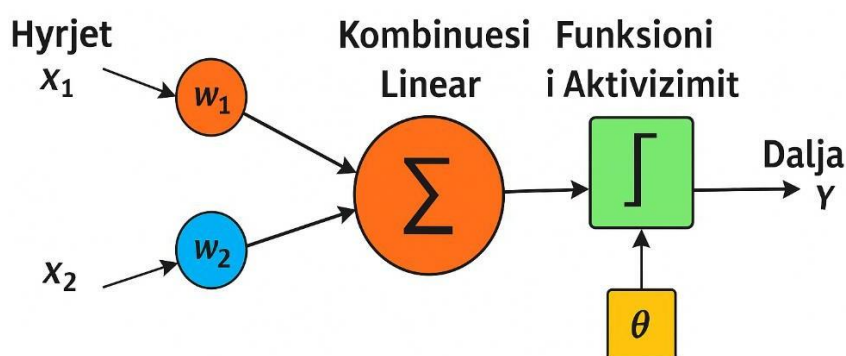
$$Y_{\text{linear}} = X$$

Grafiku 1. Funksionet e aktivizimit

Neuronet me këtë funksion përdoren kryesisht në rrjetat me prapapërhapje. Funksioni linear siguron një rezultat të barabartë me hyrjen e peshuar. Neuronet me funksionin linear përdoren zakonisht për përafrime lineare (Russell, 2009). Figura më poshtë paraqet këto funksione aktivizimi.

3.2.3 PERCEPTRONI

Frank Rosenblatt (Rosenblatt, 1958) prezantoi një algoritëm trajnimi, i cili prezantonte procedurën e parë për trajnimin e një ANN të thjeshtë të quajtur Perceptron²⁷. Një perceptron është forma më e thjeshtë e një rrjeti neural. Ai konsiston në një neuron të vetëm me pesha sinaptike të rregullueshme dhe një funksion prag. Figura më poshtë paraqet një perceptron me një shtresë dhe dy hyrje.



Figurë 6. Perceptroni me dy hyrje

Modeli konsiston në një shumatore lineare të ndjekur nga një funksion prag. Shuma e peshuar e hyrjeve, ose shkurt hyrja e peshuar X , zbatohet tek funksioni prag, i cili jep një dalje të barabartë me 1 nëse hyrja e peshuar është më e madhe ose e barabartë se vlera e pragut dhe -1 ose 0 nëse hyrja e peshuar është më e vogël se vlera e pragut.


Qëllimi i perceptronit është të klasifikojë hyrjet ose, ndryshe thuhet të klasifikojë stimujt e zbatuar së jashtmi x_1, x_2, \dots, x_n , në njërën nga dy klasat për shembull A_1 dhe A_2 . Pra në rastin e një perceptroni elementar, hapësira n -dimensionale ndahet nga një plan në dy zona klasifikimi. Plani përcaktohet nga funksioni linearisht i ndashëm:

$$\sum_{i=1}^n x_i w_i - \theta = 0$$

Në rastin e dy hyrjeve, kufijtë e ndarjes marrin formën e një drejtëze. Vlera e pragut përdoret për të zhvendosur kufijtë e ndarjes. Pika 1 mbi drejtëzë i përket klasës A_1 dhe pika 2 poshtë drejtëzës i përket klasës A_2 . Drejtëza ka ekuacionin:

$$x_1 w_1 + x_2 w_2 - \theta = 0$$


²⁷ Njësi bazë e një rrjeti nervor artificial



Grafiku 2. Ndarja lineare e perceptronit me dy hyrje

Perceptroni me tri hyrje e ka planin ndarës me tri përmasa. Në këtë rast plani përcaktohet nga ekuacioni:

$$x_1w_1 + x_2w_2 + x_3w_3 - \theta = 0$$



Grafiku 3. Plani ndarës në Perceptronin me tri hyrje

Si i mëson një perceptron punët klasifikuese?

Kjo realizohet duke bërë rregullime të vogla në peshat për të zvogëluar diferencën midis daljes aktuale dhe daljes së dëshiruar të perceptronit. Peshat fillestare përcaktohen të rastit, zakonisht nga segmenti $[-0.5: 0.5]$ dhe pastaj modifikohen për të përcaktuar një dalje të qëndrueshme në shembujt trajnues. Për një perceptron procesi i modifikimit të peshave është i thjeshtë.

Nëse në ciklin p dalja aktuale është $Y(p)$ dhe dalja e dëshiruar është $Y_d(p)$, atëherë gabimi jepet nëpërmjet: $e(p) = Y_d(p) - Y(p)$ ku $p = 1, 2, 3 \dots$

Cikli p i referohet shembullit trajnues p të paraqitur tek perceptroni.

Nëse gabimi $e(p)$ është pozitiv, atëherë rrjeti ka nevojë të rrisë daljen e perceptronit $Y(p)$, por nëse është negativ, duhet të zvogëlojë daljen $Y(p)$. Duke marrë në konsideratë faktin që çdo hyrje e perceptronit $x_i(p) * w_i(p)$ kontribuon në hyrjen totale $X(p)$, gjendet se, nëse hyrja $x_i(p)$ është pozitive atëherë një rritje e peshës së tij $w_i(p)$ tenton të rrisë daljen e perceptronit $Y(p)$, ndërsa nëse një hyrje është negative, një rritje në peshë tenton të zvogëlojë $Y(p)$.

Pra rregulli i nxënies së perceptronit ose rregulli delta është:

$$w_i(p + 1) = w_i(p) + \alpha \cdot x_i(p) \cdot e(p)$$

Ku, α është shpejtësia e nxënies, një konstante pozitive më e vogël se 1. Duke pasur si bazë këtë rregull krijohet algoritmi i trajnimit të perceptronit për punët e klasifikimit. Hapat e Algoritmit (Rosenblatt, 1958):

Hapi I. Inicializimi

Përcaktohen peshat fillestare w_1, w_2, \dots, w_n dhe vlera e pragut θ me vlera të rastit nga segmenti $[-0.5: 0.5]$.

Hapi II. Aktivizimi

Aktivizohet perceptroni duke përdorur hyrjet $x_1(p), x_2(p), \dots, x_n(p)$ dhe dalja e dëshiruar $Y_d(p)$. Llogaritet dalja aktuale në ciklin $p = 1$.

$$Y(p) = \text{binar} \left[\sum_{i=1}^n x_i(p) * w_i(p) - \theta \right]$$

ku n - numri i hyrjeve të perceptronit dhe *binar* – funksioni binar i aktivizimit

Hapi III. Modifikimi i peshave

Modifikohen peshat e perceptronit me qëllim përshtatjen e tyre sipas modelit të serisë:

$$w_i(p + 1) = w_i(p) + \Delta w_i(p)$$

ku, $\Delta w_i(p)$ - modifikimi i peshës në ciklin p . Modifikimi i peshës llogaritet nga rregulli delta:

$$\Delta w_i(p) = \alpha \cdot x_i(p) \cdot e(p)$$

Hapi IV. Përsëritja

Rritet cikli p me 1 njësi, procesi kthehet sërish tek hapi 2 dhe algoritmi përsëritet derisa rrjeti të konvergojë.

Një perceptron mund të mësojë vetëm funksione linearisht të ndashëm.

Fakti që një perceptron mund të mësojë vetëm funksione linearisht të ndashëm rrjedh direkt nga ekuacioni: $x_1 \cdot w_1 + x_2 \cdot w_2 = \theta$. Dalja Y e perceptronit është 1 vetëm nëse hyrja e peshuar X është më e madhe se vlera e pragut. Kjo nënkupton se, e gjithë hapësira e hyrjeve ndahet në dy zona të përcaktuara nga $X = \theta$.

Psh, një drejtëz lineare për operacionin AND përcaktohet nga ekuacioni:

$$x_1 \cdot w_1 + x_2 \cdot w_2 = \theta$$

Nëse zëvendësohen vlerat për peshat w_1 , w_2 dhe θ përfitohet një nga drejtëzat e mundshme:

$$0.1 \cdot x_1 + 0.1 \cdot x_2 = 0.2 \quad \text{ose} \quad x_1 + x_2 = 2$$

Pra, zona poshtë drejtëzës, ku dalja është 0, jepet nga inekuacioni:

$$x_1 + x_2 - 2 < 0$$

dhe zona sipër drejtëzës, ku dalja është 1, jepet nga inekuacioni:

$$x_1 + x_2 - 2 \geq 0$$

Fakti se, një perceptron mund të mësojë vetëm funksione linearisht të ndashme është një fakt relativisht negativ duke qenë se, nuk ka shumë funksione të tilla.

Po problemet që nuk janë linearisht të ndashëm si trajnohen?

Për të trajtuar problemet të cilat nuk janë linearisht të ndashëm përdoren rrjetat neurale me shumë shtresa. Kufizimet që shfaqen tek perceptroni mund të kalohen tek format e avancuara të rrjetave neurale, si tek perceptronet me shumë shtresa të trajnuara me algoritmin me prapapërhapje.

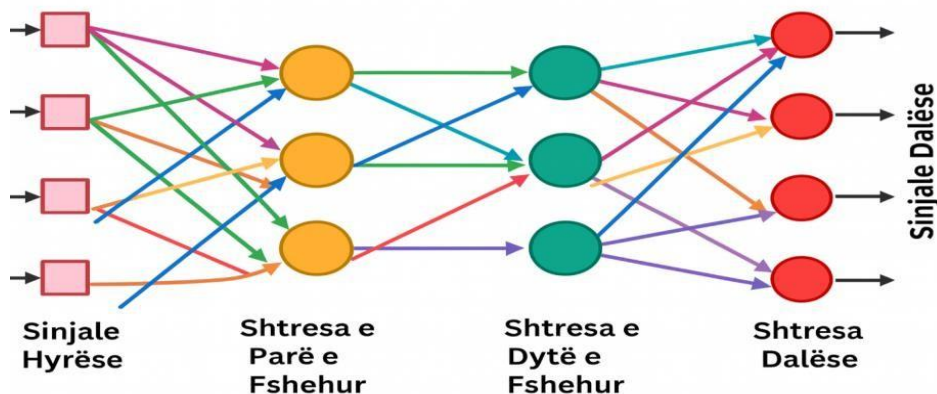
3.2.4 PERCEPTRONI ME SHUMË SHTRESA (MLP)

Rrjeti neural me shumë shtresa ose Perceptroni me shumë shtresa është një rrjet neural i drejtëpërdrejtë me një ose më shumë shtresa të fshehura.

Rrjetat me shumë shtresa janë provuar se, janë në gjendje të përafrojnë çdo funksion të vazhdueshëm duke gjetur numrin e përshtatshëm të neuroneve në shtresën e fshehur, me disa raste të suksesshme zbatimi (Hornik *et. al.*, 1989; Guo *et. al.*, 2009; Bojorquez *et. al.*, 2012; Shao, 2013).

Rrjeti konsiston në një shtresë hyrëse të neuroneve burim, të paktën në një shtresë të fshehur të neuroneve llogaritëse dhe një shtresë dalëse me neurone llogaritëse. Sinjalet e hyrjes përparojnë në drejtimin nga shtresa hyrëse drejt shtresës dalëse.

Një rrjet me dy shtresa të fshehura tregohet në figurën e mëposhtme.



Figurë 7. Rrjeti neural me dy shtresa të fshehura

Përse nevojitet shtresa e fshehur?

Çdo shtresë në një perceptron me shumë shtresa ka funksionin e saj specifik. Shtresa e hyrjes pranon sinjalet e hyrjes nga bota e jashtme dhe rishpërndan këto sinjale tek të gjitha neuronet në shtresën e fshehtë. Shtresa e hyrjes rrallë mund të përfshijë neurone llogaritëse. Shtresa e daljes pranon sinjalet e daljes nga shtresa e fshehur dhe përcakton modelin e daljes së gjithë rrjetit.

Neuronet në shtresën e fshehur shërbejnë për nxjerrjen e tipareve; peshat e neuroneve të tyre paraqesin tiparet e fshehura në modelet hyrëse. Këto tipare përdoren prej shtresës dalëse në përcaktimin e modelit të daljes.

Përse shtresat e mesme në një rrjet quhen shtresa të ‘fshehura’?

Një shtresë e fshehur fsheh daljen e saj të dëshiruar. Neuronet në shtresën e fshehur nuk mund të vëzhgohen përmes sjelljes hyrëse/dalëse të rrjetit. Nuk ka një mënyrë të dukshme për të ditur cila duhet të jetë dalja e shtresës së fshehur. Pra dalja e kësaj shtrese përcaktohet nga vetë shtresa.

A mund të ketë një rrjet neural më tepër se dy shtresa të fshehura?

Rrjetat neurale komerciale mund të kenë edhe tri apo katër shtresa, duke përfshirë një ose dy shtresa të fshehura. Rrjetat neurale eksperimentale mund të kenë edhe 5 ose 6 shtresa, duke përfshirë tri ose katër shtresa të fshehura dhe përdorin miliona neurone, por në praktikë përdorin vetëm tri shtresa (pra një shtresë e fshehur), sepse shtresat shpesh rrisin sasinë e llogaritjeve në rrjet.

Si mësojnë rrjetat neurale me shumë shtresa?

Ekzistojnë më shumë se 100 lloje algoritmesh të nxënies, por metodat më të përdorshme bazohen te algoritmi me prapapërhapje. Nxënia në një rrjet me shumë shtresa ngjason me nxënien e perceptronit. Të dhënat e trajnimit paraqiten te rrjeti. Ky i fundit llogarit modelin e tij dalës dhe gabimin, një diferencë midis daljes aktuale dhe asaj të dëshiruar. Peshat përshtaten dhe rregullohen nga algoritmi i trajnimit për të zvogëluar pikërisht këtë gabim.

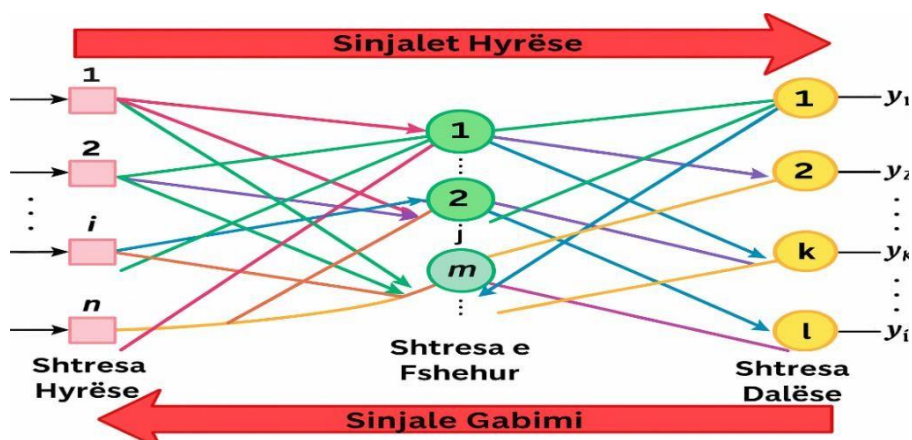
Një perceptron ka vetëm një peshë për çdo hyrje dhe vetëm një dalje. Ndërsa rrjetat me shumë shtresa kanë disa pesha për çdo hyrje dhe secila prej tyre shërben për më shumë se një dalje. Si mund ta masim një gabim dhe ta ndajmë atë sipas peshave që kanë kontribuar? Algoritmi i nxënies me prapapërhapje ka dy faza. Si fillim, bashkësia trajnuese prezantohet në shtresën hyrëse të rrjetit. Rrjeti më pas përhap modelin hyrës nga shtresa në shtresë derisa një model dalje gjenerohet në shtresën e daljes. Nëse ky model është i ndryshëm nga dalja e dëshiruar, llogaritet një vlerë gabimi e cila më pas përhapet në drejtim të kundërt përmes rrjetit nga shtresa e daljes drejt shtresës së hyrjes. Ndërkohë që gabimi përhapet, peshat modifikohen.

Një rrjet me prapapërhapje, si çdo rrjet tjetër, përcaktohet nga lidhjet ndërmjet neuroneve, nga funksioni i aktivizimit dhe algoritmi i nxënies, i cili përcakton procedurën për modifikimin e peshave. Në përgjithësi një rrjet me prapapërhapje është një rrjet që ka tri ose katër shtresa. Shtresat janë plotësisht të lidhura me njëra tjetrën, pra çdo neuron në çdo shtresë lidhet me çdo neuron të shtresës pasardhëse.

Një neuron përcakton daljen e tij në të njëjtën mënyrë si perceptroni, ku fillimisht llogaritet hyrja e peshuar e rrjetit dhe më pas në sajë të funksionit të aktivizimit, i cili është funksioni sigmoidal, përcaktohet dalja.

$$X = \sum_{i=1}^n x_i w_i - \theta \qquad Y^{sigmoid} = \frac{1}{1+e^{-X}}$$

Rregulli i nxënies në rrjetat me prapapërhapje
 Konsiderohet një rrjet me tri shtresa si më poshtë:



Figurë 8. Rrjeti me Prapapërhapje me tri shtresa

Indekset i, j, k i referohen përkatësisht neuroneve në shtresën hyrëse, të fshehur dhe dalëse. Sinjalet hyrëse x_1, x_2, \dots, x_n shpërndahen në të gjithë rrjetin nga e majta në të djathtë dhe sinjalet e gabimit e_1, e_2, \dots, e_l në drejtim të kundërt, nga e djathta në të majtë. Simboli w_{ij} përcakton peshën për lidhjen midis neuronit i në shtresën hyrëse dhe neuronit j në shtresën e fshehur, w_{jk} - pesha midis neuronit j në shtresën e fshehur dhe neuronit k në shtresën dalëse.


Për të shpërndarë sinjalet e gabimit fillohet nga shtresa dalëse drejt shtresës së fshehur. Sinjali i gabimit në daljen e neuronit k në ciklin p është:

$$e_k(p) = y_d, k(p) - y_k(p)$$

Neuroni k , që ndodhet në shtresën dalëse, e vendos vetë vlerën e daljes së dëshiruar. Për këtë arsye duhet që të përdoret një procedurë e qartë për të përditësuar peshën w_{jk} . Në fakt, rregulli i përditësimit të peshave në shtresën e daljes është i njëjtë me rregullin e nxënies për perceptronin:

$$w_{jk}(p + 1) = w_{jk}(p) + \Delta w_{jk}(p)$$

Për të përcaktuar korigjimin e peshës tek perceptroni u përdor sinjali hyrës x_i , ndërsa në rrjetin me shumë shtresa hyrjet e neuronit në shtresën e daljes janë të ndryshme nga hyrjet e neuroneve në shtresën hyrëse.



Grafiku 4. Modifikimi i peshave në mënyrë gradiente

Në vend të vlerës hyrëse x_i përdoret dalja e neuronit j në shtresën e fshehur y_j . Vlera e korrigjuar e peshës në rrjetin me shumë shtresa llogaritet (Fu, 1994):

$$\Delta w_{jk}(p) = \alpha \cdot y_j(p) \cdot \delta_k(p)$$

ku $\delta_k(p)$ është gradienti i gabimit në neuronin k të shtresës së daljes në ciklin p , i cili është përcaktuar si derivat i funksionit të aktivizimit shumëzuar me gabimin në daljen e neuronit.

Kështu, për neuronin k në shtresën e daljes gradienti i gabimit është:

$$\delta_k(p) = \frac{\partial y_k(p)}{\partial X_k(p)} * e_k(p)$$

ku, $y_k(p)$ është dalja e neuronit k në ciklin p dhe $X_k(p)$ është hyrja e peshuar e rrjetit tek neuroni k në të njëjtin cikël. Për funksionin sigmoid ekuacioni mund të paraqitet:

$$\delta_k(p) = \frac{\partial \left\{ \frac{1}{1 + e^{-X_k(p)}} \right\}}{\partial X_k(p)} \cdot e_k(p) = \frac{e^{-X_k(p)}}{(1 + e^{-X_k(p)})^2} \cdot e_k(p)$$

Nga kjo merret:

$$\delta_k(p) = y_k(p) \cdot [1 - y_k(p)] \cdot e_k(p)$$

Hapat e algoritmit të trajnuar me Prapapërhapje:

Hapi I: Inicializimi

Gjenerohen në mënyrë rastësore vlerat e peshave dhe vlera e pragut të marra nga segmenti (Haykin, 1999);

$$\left(\frac{-2.4}{F_i}, +\frac{2.4}{F_i}\right)$$

ku F_i është numri total i hyrjeve të neuronit i në rrjet. Inicializimi i peshave bëhet për çdo neuron.

Hapi II: Aktivizimi

Aktivizojmë rrjetin duke aplikuar hyrjet $x_1(p), x_2(p), \dots, x_n(p)$ dhe daljet e dëshiruara $y_{d,1}(p), y_{d,2}(p), \dots, y_{d,n}(p)$.

Llogarisim daljet aktuale të neuroneve në shtresën e fshehur

$$y_j(p) = \text{sigmoid}\left[\sum_{i=1}^n x_n(p)w_{ij} - \theta_j\right]$$

ku, n është numri i hyrjeve të neuronit j në shtresën e fshehur. Llogarisim daljet aktuale të neuroneve në shtresën e daljes:

$$x_{kp}(p) = \text{sigmoid}\left[\sum_{j=1}^m x_{jk}(p)w_{jk} - \theta_k\right]$$

ku m është numri i hyrjeve të neuronit k në shtresën e daljes.

Hapi III: Modifikimi i peshave

Përditësohen peshat në rrjetin me prapapërhapje duke kthyer pas gabimet.

Llogaritet gradienti i gabimit për neuronet në shtresën e daljes:

$$\delta_k(p) = y_k(p) * [1 - y_k(p)] * e_k(p)$$

ku, $e_k(p) = y_{d, k}(p) - y_k(p)$

Llogariten korigjimet e peshave: $\Delta w_{jk}(p) = \alpha \cdot y_j(p) \cdot \delta_k(p)$

$$\delta_j(p) = y_j(p) \cdot [1 - y_j(p)] \cdot \sum_{k=1}^l \delta_k(p) \cdot w_{jk}(p)$$

Përditësohen peshat e neuroneve të daljes: $w_{jk}(p + 1) = w_{jk}(p) + \Delta w_{jk}(p)$

Llogaritet gradienti i gabimit për neuronet në shtresën e fshehur:

Llogariten korrigjimet e peshave: $\Delta w_{ij}(p) = \alpha \cdot x_i(p) \cdot \delta_j(p)$.

Përditësohen peshat në neuronet e fshehura: $w_{ij}(p + 1) = w_{ij}(p) + \Delta w_{ij}(p)$

Hapi IV: Përsëritja

Rritet cikli p me 1, shkohet në ciklin e dytë dhe përsëritet procesi derisa të plotësohet kriteri i gabimit.

Shuma e katrorëve të gabimeve

Shuma e katrorëve të gabimeve është shuma e diferencave të daljeve target (të dëshiruara) me daljet aktuale të rrjetit, të ngritura në katror, për një vektor hyrjesh. Ai është një tregues i nevojshëm për performancën e rrjetit. Algoritmi me prapapërhapje²⁸ përpiqet që të zvogëlojë këtë kriter. Kur vlera e shumës së katrorëve të gabimeve gjatë gjithë procesit arrin të jetë mjaftueshëm i vogël thuhet se, rrjeti ka konverguar.

A është algoritmi me prapapërhapje një metodë e mirë për trajnimin e rrjetave?

Edhe pse përdoret gjerësisht, nxënia me prapapërhapje nuk është rezistent ndaj problemeve. Ky algoritëm me sa duket nuk ekziston në botën biologjike. Neuronet biologjike nuk e përcjellin informacionin pas për të rregulluar fuqinë apo peshat e lidhjeve të tyre dhe kështu nxënia me prapapërhapje nuk duhet të shihet si një proces që simulon nxënien sipas trurit tonë. Një problem tjetër është se, llogaritjet janë të shumta dhe si rezultat trajnimi është i ngadaltë. Në fakt një algoritëm i pastër me prapapërhapje përdoret rrallë në praktikë. Ka disa mundësi për të përmirësuar eficiencën llogaritëse të këtij algoritmi (Negnevitsky, 2011). Një rrjet neural me shumë shtresa mëson më mirë nëse funksioni i aktivizimit sigmoidal është i llojit tangent hiperbolik:

$$Y^{\tanh} = \frac{2a}{1 + e^{-bx}} - a$$

ku a dhe b janë konstante, zakonisht $a = 1,716$; $b = 0,667$.

Metodë tjetër për përshpejtimin e procesit të nxënies së rrjetit është përfshirja e koeficientit të momentit në rregullin delta.

$$\Delta w_{jk}(p) = \beta \cdot \Delta w_{jk}(p - 1) + \alpha \cdot y_j(p) \cdot \delta_k(p)$$

ku β është një numër pozitiv nga 0 në 1, i quajtur koeficienti i momentit. Ekuacioni më sipër quhet rregulli i përgjithësuar delta.

²⁸ BackPropagation

Rëndësia e konstantes së momentit qëndron në efektin stabilizues të trajnimit. Ndryshe thuhet se, konstantja e momentit tenton të përshpejtojë zbritjen e gabimit drejt një vlere të qëndrueshme, ose deri sa ajo të konvergojë.

Në rregullin delta dhe në rregullin e përgjithësuar delta përdoret një konstante me vlerë të vogël, që quhet shpejtësia e nxënies. Mund të rritet kjo vlerë në mënyrë që të përshpejtohet trajnimi? Një nga mënyrat më efektive për të përshpejtuar konvergencën e algoritmit me prapapërhapje është rregullimi i shpejtësisë së nxënies gjatë trajnimit. Një vlerë e vogël e shpejtësisë së nxënies sjellë ndryshime të vogla në peshë nga një cikël në tjetrin, kështu që, kjo sjellë një kurbë të lëmuar të nxënies. Nga ana tjetër, nëse shpejtësia e nxënies rritet për të përshpejtuar procesin e trajnimit, ndryshimet e peshave do të jenë më të mëdha. Kjo mund të sjellë joqëndrueshmëri dhe si rezultat rrjeti mund të ketë lëkundje. Për të përshpejtuar konvergencën dhe për të shmangur rrezikun e paqëndrueshmërisë, mund të zbatohen dy heuristika:

Heuristika 1. Nëse ndryshimi i shumës së gabimeve në katror ka të njëjtën shenjë për shumë epoka të njëpasnjëshme atëherë shpejtësia e nxënies duhet të rritet.

Heuristika 2. Nëse shenja e ndryshimit të shumës së katrorëve të gabimeve alternohet për disa epoka të njëpasnjëshme atëherë shpejtësia e nxënies duhet të zvogëlohet.

Përshtatja e shpejtësisë së nxënies kërkon disa ndryshime në algoritmin me prapapërhapje. Si fillim, daljet dhe gabimet e rrjetit llogariten në bazë të vlerës fillestare të shpejtësisë së nxënies. Nëse shumën e katrorëve të gabimeve për periudhën aktuale e tejkalon vlerën e mëparshme duke pasur një raport 1.04 me 1, shpejtësia e nxënies zvogëlohet dhe llogariten peshat dhe vlerat e reja të pragut.

Sidoqoftë, nëse gabimi është më i vogël se vlera e tij e mëparshme, parametri i shpejtësisë së nxënies rritet. Kjo tregon se, përshtatja e parametrin mund të zvogëlojë numrin e cikleve. Studimi i përshtatjes së këtij parametri mund të përdoret së bashku me studimin e koeficientit të momentit. Kjo ndërthurje përmirëson performancën e një rrjeti neural me prapapërhapje dhe minimizon mundësinë e rrjetit për t'u sjellë si oshilator.

3.2.5 RRJETAT NEURALE JOLINEARE AUTOREGRESIVE (NARNN¹⁰)

Rrjetat Neurale Jolineare Autoregresive janë rrjeta neurale dinamike bazuar në modelin jolinear autoregresiv, pa pasur nevojën e asnjë treguesi tjetër teknik. NAR (nonlinear autoregressive) është një model statistikor parashikimi i përdorur gjerësisht për seritë kohore (Hwang & Basawa, 1994; Guo & Xue, 2014). NAR është një model përgjithësues i modelit AR në rastin e jolinearititetit. Modeli prezantohet në këtë formë:

$$\hat{y}_t = E(y_t | y_{t-1}, y_{t-2}, \dots, y_{t-p}) = f(y_{t-1}, y_{t-2}, \dots, y_{t-p})$$

ku f është një funksion i panjohur, që ka si qëllim minimizimin e mesatares së katrorëve të gabimeve të parashikimeve y_t i varur nga ndryshoret vonesa $y_t, y_{t-1}, \dots, y_{t-p}$ (Kapetanios, 2006). Vlera e parashikuar e y_t në kohën t është:

$$\hat{y}_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p})$$

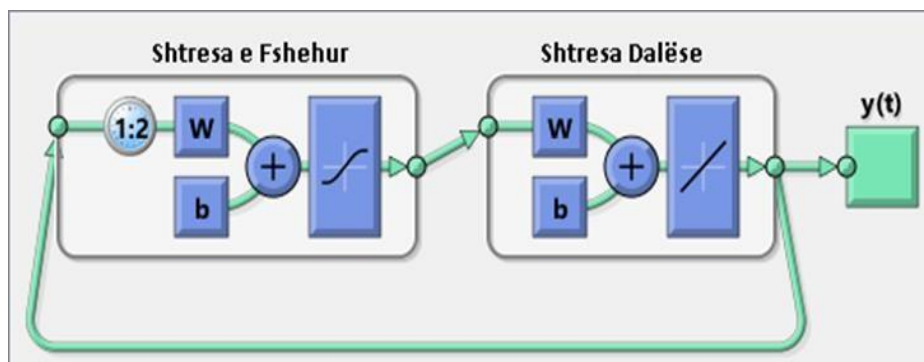
Ky model zbatohet te rrjeti neural i drejtëpërdrejtë, ku funksioni f zëvendësohet nga disa neurone që punojnë sëbashku për përafrimin e modelit (Pawlus *et. al.*, 2013; Liang, 2005).

$$\hat{y}_t = \sum_{i=1}^p b_i \Psi \left(\sum_{j=1}^p w_{ji} y_{t-j} \right)$$

ku Ψ është funksioni i aktivizimit; w_{ji} është pesha e lidhjes së një hyrje i me një neuron j në shtresën e fshehur; b_i është pesha e lidhjeve nga shtresa e fshehur në shtresën dalëse.

Rrjeti neural NAR është një lloj rrjeti neural rekurent me vonesa në kohë. Si hyrje shërben seria kohore e dhënë me vlerat e kaluara të ndryshorit y që parashikon. Këto vlera jepen nëpërmjet vonesave kohore. Rrjeti neural NAR është një rrjet neural dinamik. Rrjeti dinamik ka kujtesë. Përgjigja që ai jep në çdo kohë t varet jo vetëm nga hyrja aktuale, por edhe nga historiku i sekuencës së ndryshores hyrëse.

Trajnohet sipas algoritmit me prapapërhapje që përdor linjat kthyesë (feedback-u) për përafrimin e funksioneve jolineare. Në shtresën e fshehur (zakonisht një shtresë e fshehur) përdoret funksioni sigmoidal i aktivizimit dhe funksioni linear për shtresën dalëse. Linja kthyesë nga dalja përdoret si një hyrje e rrjetit.



Figurë 9. Arkitektura e Rrjetit Neural NAR

Dalja e një rrjeti neural konsiderohet ajo vlerë që llogaritet nga sistemi dinamik jolinear që kërkohet të modelohet. Kjo dalje duhet të kthehet në hyrje të rrjetit të drejtëpërdrejtë si pjesë e arkitekturës standarte të NAR. Gjatë fazës së trajnimit, meqenëse rrjeti disponon vlerën target të daljes nga bashkësia e trajnimit, mund të krijohet një arkitekturë me cikël të hapur, ku vlera target të përdoret si hyrje me anë të ciklit, në vend të daljes së llogaritur nga rrjeti.

Kjo ka dy përfitime në modelim:

1. hyrja e rrjetit është më e saktë
2. rrjeti rezultues ka një arkitekturë të drejtëpërdrejtë të pastër (Huo & Poo, 2013).

Cikli qëndron i hapur gjatë procesit të trajnimit të rrjetit. Vetëm pasi të jetë trajnuar rrjeti, cikli mbyllet (konfigurimi paralel) me qëllim që të kryhet parashikimi për disa hapa të mëtejshme. Për secilën nga hyrjet ekziston një linjë e caktuar vonese për të ruajtur vlerat e mëparshme.

Përcaktimi i numrit të neuroneve hyrëse është një nga vendimet kritike në problemet e parashikimit të serive kohore, duke qenë se përmban informacion të rëndësishëm për të dhënat. Në këtë studim meqë përdoret analiza univariate, vetëm me një ndryshore, numri i hyrjeve korrespondon me numrin e vonesave kohore të vetë ndryshores së varur, e cila këtu përcaktohet nga modeli autoregresiv. Në rastin më të mirë do të ishte një numër i vogël neuronesh, pasi kjo mund të zbulojë veçoritë unike të përfshira të të dhënat. Një numër shumë i madh apo shumë i vogël neuronesh hyrëse do të ndikonte negativisht në aftësinë e nxënies së rrjetit, si rrjedhojë dhe në parashikimin e tij.

Gjatë përcaktimit të arkitekturës së rrjetit NARNN duhet të zgjidhen vonesat që lidhen me secilën linjë vonese, po ashtu edhe numrin e neuroneve të fshehura. Numri i neuroneve të fshehura nuk është i specifikuar apriori. Kjo mund të përcaktohet nëpërmjet testimeve. Këto neurone mundësojnë zbulimin dhe nxjerrjen e njohurive të fshehura të seria që studiohet. Hornik et. al., (1989) në studimin e tij zbuloi se, një shtresë e vetme e fshehur ishte e mjaftueshme për përafrimin e një funksioni jolinear. Po ashtu, shumica e studiuesve përdorin vetëm një shtresë të fshehur për problemin e parashikimit. Edhe në këtë studim është përdorur arkitektura me një shtresë të fshehur.

Për modelimin dhe parashikimin e serive në studim u zgjodh rrjeti neural NAR pasi është një rrjet dinamik, mund të trajnohet për të njohur modele që ndryshojnë në kohë. Është më i fuqishëm nga ana llogaritëse se rrjeti statik për shkak të aftësisë së memorizimit. Përdorimi i ciklit të këto modele sjellë krijimin e një rrjeti më të saktë (Zhou et. al., 2014).

3.3 MODELI PARASHIKUES I RRJETIT NEURAL

Rrjetat Neurale duhet të zhvillojnë sjellje inteligjente të suksesshme ashtu si tregtarët e suksesshëm të cilët përdorin analizën e tregut duke e kombinuar atë me njohuritë dhe aftësitë e tyre. Me zhvillimet që ka arritur sot teknologjia kompjuterike, këto sisteme mund të kapërcejnë disa nga kufizimet e njeriut, si koeficienti i ulët i efikasitetit.

Si pjesë e tregut financiar edhe problemi i parashikimit të serive kohore mund të gjejë zgjidhje mjaft të kënaqshme trajnuar me anë të këtij sistemi inteligjent sikurse e kanë prezantuar edhe shumë studime (Hann, & Steurer, 1996; Dunis et. al., 2002, Dunis et. al., 2011; Longmore & Robinson, 2004).

Ato janë përdorur për të këshilluar tregjet financiare me qëllim rritjen e përfitimeve. ANN në problemin e parashikimit janë sisteme që janë në gjendje të përshtaten, të njohin modele, të përgjithësojnë dhe të klasifikojnë të dhëna. Në mënyrë që ANN të njohin modele të dhënash është e nevojshme që të mësojnë strukturën e të dhënave. Janë bërë kërkime dhe zbatime të rrjetave neurale për parashikime të ndryshme.

Kërkimet në parashikimin e serisë kohore

Fusha e parashikimeve të serive kohore përgjithësisht përqëndrohet në parashikimin e vlerave të së ardhmes të serisë në një nga dy mënyrat: ose parashikon vlerat e një serie nga vlerat e kaluara të saj ose duke përdorur të dhënat nga seri të ndryshme. Chan dhe Foo (1995) përdorën ANN për të parashikuar vlerat e ardhshme në seri kohore të çmimeve të aksioneve dhe përdorën këto vlera për të llogaritur tregues të fuqishëm teknik.

Kjo ANN solli rezultate premtuese dhe autorët arritën në përfundimin se, aftësia e rrjetit për të parashikuar i mundëson tregtarët të futen në treg qoftë edhe një ose dy ditë para se të sinjalizohen nga treguesit e zakonshëm teknik. Si rrjedhojë, kjo sjellë përfitime të mëdha në llogaritë e tyre. Përdorimi i ANN në parashikimin e serive financiare ka një ndikim të madh në rritjen e fitimit, nëse ai është i suksesshëm.

Kërkimet në njohjen e modeleve dhe në klasifikim

Teknikat e njohjes së modeleve dhe të klasifikimit janë grupuar së bashku duke qenë se qëllimi i tyre nuk është të parashikojnë vlera të së ardhmes në një seri kohore, por të parashikojnë drejtimin e një serie kohore. Psh, objektivi i grafistëve në 1997 ishte të parashikonin trendin e pikave duke studiuar grafikët e çmimeve për të krijuar modele të caktuara (Mitchell, 1997). Ata kanë vënë re se, këto modele tentojnë të ndodhin sërish dhe janë tregues të besueshëm të trendit të çmimeve të së ardhmes. Teknika të tjera të cilat gjithashtu përpiqen të parashikojnë trendin e së ardhmes të një serie kohore janë ato që bazohen në problemet e klasifikimit.

Kërkimet në Optimizim

Optimizimi gjendet në hulumtimet që kryejnë programet kompjuterike kryesisht për të përmiësuar një rezultat të caktuar. Për shembull, këtë stil ka përdorur Chen et. al., (2007), ku modeli i tyre përpiqet të zgjedhë saktë kohën e pikës së hyrjes dhe kohën kur konstantja anim të ketë vlerën e saj optimale në mënyrë që të rritet efienca e zgjidhjes. Hulumtimi i tyre tregoi se, teknika e rrjetit neural tejkalon dukshëm teknikat tradicionale.

Që të zhvillohet modelim dhe parashikim më i mirë me rrjetat neurale, duhet të zhvillohen disa faza paraprake:

1. Përzgjedhja e ndryshoreve

Sipas Huang et. al., (2004) hapi i parë për ndërtimin e rrjetit neural për parashikimin e një serie kohore duhet të jetë përcaktimi i ndryshoreve. Ndryshoret me të dhëna të papërpunuara janë më shumë se sa është e nevojshme. Zgjedhja e ndryshoreve kryesore për parashikim është shumë e rëndësishme. Frekuenca e përzgjedhjes së të dhënave (ditore, javore, mujore apo vjetore) varet nga qëllimet e studiuesit.

Në varësi të llojit të analizës që përcaktohet, univariate apo multivariate, kryhet dhe përzgjedhja e ndryshoreve. Nëse analiza është univariate do të merret në konsideratë vetëm seria kohore e ndryshores që do të parashikohet.

Zakonisht në këtë rast vonesat kohore do të shërbejnë si hyrje në rrjetin neural dhe si dalje vlera e parashikuar e serisë. Studiues të tjerë mund të zgjedhin analizën multivariate në të cilën merren të dhëna nga më shumë se një ndryshore. Përveç serisë kohore të ndryshores që do të parashikohet janë dhe seritë kohore, ndryshoret e të cilave ndikojnë në ndryshueshmërinë e vlerave të serisë kohore fillestare.

Walczak dhe Cerpa (1999) kanë treguar një metodë për izolimin e ndryshoreve të dobishme për rrjetat neurale multivariate. Në metodën e tyre mblidhen sa më shumë ndryshore të dobishme që të jetë e mundur, më pas fshin një nga një ato të parëndësishmet duke krahasuar performancën e rrjetit me dhe pa secilën ndryshore. *

Në studimin e Smith (2013) është arritur në përfundimin se, duhet të shmangen ndryshoret të cilat janë shumë të lidhura me serinë kohore bazë, pasi informacioni që ato përmbajnë është tashmë brenda kësaj serie dhe mund të sjellë parashikim të zhvendosur. Në këtë studim duke qenë se analiza është univariate, modeli do të ndërtohet mbi vonesat kohore.

2. Mbledhja e të dhënave

Kur mblidhen të dhënat duhet të merren parasysh kostoja dhe cilësia e tyre. Janë katër çështje që duhet të konsiderohen në këtë proces:

- 1- metoda e përlllogaritjes
- 2- të dhënat që nuk mund të modifikohen
- 3- një vonesë e të dhënave
- 4- të sigurohet se, burimi do të vazhdojë të japë të dhëna në të ardhmen.

Dhënia e shumë vonesave kohore në rrjetin neural sjellë një kompleksitet të lartë duke e bërë më të vështirë trajnimin. Gjithashtu ajo mund të sjellë ndalimin e algoritmit në një optimale lokale. Nga ana tjetër, një numër i vogël vonesash mund të jetë i pamjaftueshëm për të zbuluar veçoritë e të dhënave.

Një zgjidhje do të ishte përdorimi i kriterëve AIC dhe BIC si kriterë përzgjedhëse të modeleve trajnuese bazuar në informacion për përzgjedhjen e rrjetave neurale. Edhe pse kjo teknikë nuk rezulton shumë efikase, pasi nuk ka lidhje të dukshme midis përshtatjes së modelit trajnues me performancën e parashikimit nga modeli testues, është përdorur në disa raste modelesh univariate. Huang et. al., (2004) propozoi metodën e Kriterit të Autokorrelacionit për të përcaktuar strukturën e vonesave në rrjetin neural të modeleve univariate. Është një metodë e drejtuar nga të dhënat dhe nuk kërkon supozime. Në këtë studim numri i vonesave kohore është zgjidhur nga përdorimi i rrjetit NAR, ku numri i hyrjeve është i parapërcaktuar (shpjeguar në paragrafin e rrjetave NAR).

3. *Përpunimi paraprak i të dhënave*

Përpunimi paraprak i të dhënave është procesi që ndihmon rrjetin neural në trajnimin e modeleve të të dhënave. Ndryshoret hyrëse dhe dalëse, rrallë, vendosen në rrjet të papërpunuara. Përpunimi paraprak i të dhënave kryhet për të minimizuar zhurmat, për të nxjerrë në pah marrëdhënie të rëndësishme, për të zbehur shpërndarjet e ndryshueshme, si dhe për të zbuluar trendin e të dhënave.

Të dhënat e papërpunuara zakonisht shkallëzohen në vlera në mënyrë që përpunimi i tyre të kryhet në përputhje me llojin e funksionit të transferimit që do të përdoret (Mitchell, 1997). Metoda më e zakonshme është transformimi 'n- lage', ku e dhëna do të marrë si vlerë të re diferencën midis vlerës aktuale dhe vlerës me vonesë (t-n). Metoda të tjera janë transformimi i logaritmit natyror, normalizimi Gaussian, metoda e studentizuar, normalizimi min- max, etj.

Shumë studiues kanë pasur në fokusin e tyre përdorimin e metodave të ndryshme të para-përpunimit të të dhënave të rrjetit neural (Davis & Clark, 2011; Klevecka & Lelis, 2008) dhe nisur nga këto studime transformimet e të dhënave mund të kategorizohen në tri grupe:

- a) Transformimi linear, ku të dhënat kryesisht shkallëzohen në vlera brenda segmentit $[0,1]$ ose $[-1,1]$.
- b) Standartizimi statistikor, ku përdoret devijimi nga mesatarja.
- c) Funksione të ndryshme matematikore.

Nuk ekziston ndonjë rregull fiks se, kur duhet përdorur normalizimi i të dhënave. Ka raste që normalizimin e të dhënave e kryen përdorimi i peshave dhe koeficienti anim. Shanker et. al., (2006) studioi eficiencën e normalizimit të të dhënave dhe rezultoi se, metodat e normalizimit dhe transformimit jo domosdoshmërisht sjellin performancë më të mirë, sidomos kur rrjeti dhe bashkësia e të dhënave janë të mëdha.

Zhang dhe Berardi (2001) nuk gjetën ndryshime në parashikim midis rastit kur përdorën normalizimin e të dhënave të serisë kohore të kursit të këmbimit dhe rastit kur nuk përdorën.

Edhe pse normalizimi i të dhënave nuk është i detyrueshëm, shpesh herë është i pashmangshëm. Për shembull, nëse një funksion funksionon vetëm për një rang të caktuar të dhënash, rrjeti nuk do të jetë në gjendje të prodhojë rezultate dalëse jashtë këtij rangu. Për rrjedhojë duhet të normalizohet dalja e dëshiruar e rrjetit. Po nëse funksioni që zbatohet në një shtresë llogaritëse është linear, atëherë nuk është e nevojshme të kryhet normalizimi.

Procesi i parapërpunimit të të dhënave është kryesisht i rëndësishëm për modelet multivariate për arsye se, vlerat mund të kenë diferencë shumë të madhe nga njëra tjetra dhe ANN, automatikisht, u jep më tepër përparësi vlerave më të mëdha.

Rregulli për përditësimin e peshave është:

$$\Delta\omega = (\text{target} - \text{output})\text{input}' = \text{gabimi} * \text{input}'$$

Siç shihet edhe nga formula sa më i madh të jetë vektori i hyrjes, aq më i madh është efekti i tij në vektorin e peshave. Kështu nëse vektori hyrës është më i madh nga të gjithë hyrjet e tjera, vektorët hyrës më të vegjël, që të kenë efekt, duhet të paraqiten shumë herë. Zgjidhja në këtë rast është normalizimi i të dhënave.

Në këtë studim përdoret funksioni scale nga paketa R, i cili kryen normalizimin Gaussian. Kjo metodë nga studimet ka rezultuar më e mirë se të tjerat. Ibrahim (2010) ka vërtetuar se, normalizimi Gaussian është superior në krahasim me metodën min- max. Normalizimi Gaussian, si fillim llogarit devijimin standart dhe mesataren e të gjithë vektorit hyrës dhe më pas shkallëzon çdo element duke zbritur mesataren dhe pjestuar me devijimin standart. Ky njihet si $X_{normalizuar}$:

$$X_{normalizuar} = \frac{X_{aktual} - \text{Mesatare}}{\text{Devijimi Standart}}$$

4. Të dhënat e trajnimit, testimit dhe vlerësimit

Një problem delikat që mund të krijohet nga zbatimi i algoritmave trajnues është mbivendosja. Mbivendosja ndodh kur funksioni i përshtat të dhënat në mënyrë perfekte, pra gabimi është zero. Megjithatë funksioni mund të ketë luhate të mëdha midis këtyre vlerave të serisë, ai nuk ka kapur asnjë nga karakteristikat themelore të modelit. Ajo çka ndodh është se, funksioni ka kapur më së shumti zhurmat të të dhënave. Ndaj ky nuk është modelim perfekt, por një problem që krijohet për arsye të ndryshme.

Një nga mënyrat për të zgjidhur mbivendosjen dhe jo vetëm është ndarja e të dhënave hyrëse të serisë kohore në dy grupe: bashkësia e trajnimit dhe bashkësia e testimit ose në tri grupe në varësi të të dhënave duke i shtuar edhe bashkësinë e vlerësimit. Bashkësia e trajnimit është bashkësia më e madhe, rreth 70%-80% e të dhënave dhe përdoret nga rrjeti neural për të trajnuar dhe njohur modelet e të dhënave. Madhësia e bashkësisë së testimit varion nga 10% deri në 30%. Ajo përdoret për të testuar modelet e rrjetit në mënyrë që studiuesi të mund të zgjedhë modelin me performancën më të mirë. Bashkësia e testimit mund të përzgjidhet rastësisht ose nga bashkësia e trajnimit ose të jetë bashkësi të dhënash që vijon menjëherë pas bashkësisë së trajnimit.

Një teknikë më e saktë për vlerësimin e një rrjeti neural është testimi, ku bashkësitë e trajnimit, testimit dhe vlerësimit kanë elemente të njëra tjetra. Bashkësia e vlerësimit, afërsisht 10 % e të dhënave përdoret për të bërë një kontroll përfundimtar mbi efikasitetin e rrjetit të trajnuar. Bashkësia e vlerësimit duhet të përzgjidhet nga vëzhgimet e të dhënave më të fundit. Ndarja kryhet bazuar në eksperiencën e autorit.

5. Arkitektura e Rrjetit Neural

Rrjetat neurale mund të gjenden në forma të ndryshme sikurse janë shpjeguar dhe në paragrafet e mësipërme. Në varësi të mënyrës së lidhjes së neuroneve, të numrit të shtresave, të transferimit të informacionit dhe funksioneve të aktivizimit njihen disa arkitektura rrjetash neural: rrjet i drejtëpërdrejtë, rrjet ciklik, rrjet perceptron me shumë shtresa, perceptron i thjeshtë, rrjet Hebbian, rrjet Hopfield, rrjet NAR, rrjeti RBF etj... Përcaktimi i arkitekturës kryhet në varësi të problemit.

Ka shumë mënyra për të ndërtuar një rrjet neural. Si fillim, duhet të përcaktohen për çdo rrjet të ri numri i neuroneve të hyrjes, numri i shtresave të fshehura, numri i neuroneve të fshehura, numri i neuroneve të daljes dhe funksionet e transferimit. ANN komerciale mund të përmbajnë tri ose katër shtresa duke përfshirë një ose dy shtresa të fshehura. Rrjetat neurale eksperimentale mund të kenë 5 ose edhe 6 shtresa duke përfshirë 3 ose 4 shtresa të fshehura, por në praktikë përdoren vetëm 3 shtresa, sepse çdo shtresë shtesë rrit ngarkesën e njehsimit në mënyrë eksponenciale. Rregulli është që gjithmonë të zgjidhet rrjeti me efikasitetin më të lartë në testim dhe me një numër sa më të vogël neuronesh të fshehura (Sheela & Deepa, 2013). Për përcaktimin e numrit të neuroneve të fshehura ka studime të shumta.

Sipas Yuan et. al., (2003) numri më i përshtatshëm i neuroneve të fshehura llogaritet bazuar në entropinë e informacionit. Qëllimi është që të shmanget mbivendosja, për shkak të tejkalimit të numrit të neuroneve të fshehura dhe për të shmangur pamjaftueshmërinë për të kapur njohuritë nga numri i vogël i neuroneve të fshehura. Pra të gjendet një numër që t'i balancojë këto dy efekte.

Në vitin 2007, Wu dhe Hong (Wu & Hong, 2007) propozuan algoritma trajnimi për përcaktimin e numrit të neuroneve të fshehura. Panchal et. al., (2011) propozuan një metodologji për të përcaktuar arkitekturën e MLP. Sipas këtij studimi numri i shtresave të fshehura është në përpjestim të drejtë me gabimin minimal. Numri i neuroneve të fshehura të rrjetit neural të avancuar vendoset në bazë të përvojës.

Duke qenë se rrjetat me shumë neurone të fshehura përgjithësisht nuk prodhojnë rezultate të mira, përdoret një numër i kufizuar i tyre. Numri i neuroneve dalëse përcaktohet nga numri i daljeve të problemit. Funksioni i transferimit është që të ekulibrojë rezultatet duke mos lejuar që ato të marrin vlera të mëdha të cilat më pas mund të çaktivizojnë rrjetin. Shumica e modeleve përdorin funksionin sigmoid, tangent ose linear. Funksioni sigmoid përdoret zakonisht për të dhënat në seri kohore të tregjeve financiare, i cili nuk është linear dhe ndryshon vazhdimisht. Në varësi të problemit mund të përdoren edhe funksione të tjera.

6. Vlerësimi i Rrjetit

Vlerësimi i rrjetit neural ose matja e performancës kryhet në bazë të shumës së katrorëve të gabimeve. Gabimet e vogla në parashikim dhe përfitimet në treg nuk janë domosdoshmërisht të njëjta. Përzgjedhja e serisë kohore duke eliminuar shumë ndryshime të vogla të çmimeve mund të sjellë rritje të përfitimeve të rrjetit. Është vënë re se, rrjetat neurale mund të jenë më të dobishme nëse seritë kohore sillen ndryshe nga modelet tradicionale të metodave parashikuese.

7. Trajnimi i rrjetit neural

Procesi i trajnimit të rrjetit neural përdor një algoritëm trajnimi që rregullon peshat për të arritur një gabim global sa më të vogël. Procesi kërkon një sërë shembujsh me hyrjet dhe daljet e dëshiruara. Gjatë trajnimit peshat e rrjetit përshtaten për të zvogëluar funksionin e performancës së rrjetit. Trajnimi përfundon ose kur ka kryer një numër të caktuar ciklesh ose epokash, i cili është parapërcaktuar ose mund të ndalojë algoritmi kur nuk mund të trajnojë më rrjetin neural dhe kjo për arsye mbivendosje. Mbivendosja gjatë trajnimit ndodh kur gabimi ka arritur të zvogëlohet së tepërmi, por me ardhjen e një vlere të re ai rritet. Përdorimi i sistemeve inteligjente në parashikimin e tregjeve financiare gjithashtu kombinon shumë lloje të tjera teknikash për të zhvilluar sjellje të suksesshme të ngjashme me metodat e suksesshme të përdorura, p.sh., algoritmat e trajnimit dhe strukturat e ndryshme të rrjetit. Nuk ekziston asnjë mënyrë fikse për të bërë parashikime 100% të sakta, kështu që, analiza e rrezikut të menaxhimit bazuar në njohuritë e ekspertëve është gjithashtu e nevojshme.

8. Testimi

Kjo fazë siguron një testim të cilësisë së rrjetit. Gabimi që bëhet zakonisht është testimi i rrjetit nga e njëjta bashkësi me atë të trajnimit, pasi kjo do të sillte mbivendosje. Është e rëndësishme të kuptohet se, funksioni jo vetëm që duhet të përshkruajë të dhënat e trajnimit, por gjithashtu duhet të jetë në gjendje të përgjithësojë të dhënat që nuk i ka hasur më parë. Nëse gabimi i performancës në modelim është i ulët dhe në testim është i lartë atëherë ka ndodhur një mbivendosje të bashkësia e trajnimit.

Modelet e përshtatura kanë modeluar zhurmën e serisë kohore dhe jo modelin e vërtetë, sikurse u trajtua dhe pak më lartë. Ndaj është e rëndësishme që faza e testimit të kryhet pas trajnimit me një bashkësi të dhënash të ndryshme nga ajo e trajnimit. Faza e testimit është e rëndësishme për kontrollin e besueshmërisë së rrjetit neural, por njëkohësisht për kryerjen e parashikimit të vlerave të reja. Kjo aftësi për të mësuar nga të dhënat dhe për të përgjithësuar në situata të panjohura përfaqëson një nga shtyllat kryesore të Nxënies Automatike (Machine Learning), një degë themelore e Inteligjencës Artificiale.

KAPITULLI 4

MODELET KLASIKE DHE MODERNE PËR ANALIZIMIN DHE PARASHIKIMIN E SERIVE KOHORE

Parashikimi i serive kohore me shkallë të lartë saktësie po merr vëmendje të madhe në shumë fusha, veçanërisht në tregjet financiare. Qëllimi i parashikimit të serive kohore është t'u ofrojë investitorëve dhe analistëve financiarë udhëzime të besueshme. Ndaj, janë zhvilluar një tërësi kërkimesh për të zhvilluar teknika sa më të sakta. Një mënyrë për të përfutur parashikime të kënaqshme është kombinimi i disa teknikave. Shumë studiues për të reduktuar gabimin e parashikimit kombinonjë metoda, që variojnë në nivel kompleksiteti dhe efikasiteti.

Motivi i përdorimit të një metode hibride në modelimin dhe parashikimin e serive kohore vjen për disa arsye: Rrallë ndodh që seritë kohore të jenë të pastra me modele vetëm lineare ose jolineare. Në shumicën e rasteve i përmbajnë të dy strukturat. Përdorimi vetëm i një metode lineare si, ARIMA, ose vetëm një metode jolineare si, ANN, nuk mund të jenë të përshtatshme në modelim. Është e vështirë nga ana praktike të përcaktohet nëse seria në studim gjenerohet nga një proces linear apo jolinear. Pra, përzgjedhja vetëm e një metode të pastër për modelim është e vështirë. Sot, në botë është e ditur se, nuk ekziston asnjë model i vetëm që të jetë më i përshtatshmi për çdo situatë të serisë kohore. Kjo për faktin se, shpesh problemet reale janë komplekse dhe çdo metodë e përdorur e vetme nuk mund t'i njoh mirë të gjitha modelet e ndryshme brenda të njëjtës seri. Sikurse është përmendur dhe më parë, një seri mund të jetë e përbërë nga të dyja strukturat, lineare dhe jolineare.

Kështu që, një kombinim i përshtatshëm i dy modeleve lineare dhe jolineare do të krijonte një model më të saktë parashikimi se modelet e përdorura veçmas. Modelet hibride duke përdorur metodën sasiore, ARIMA dhe metodën inteligjente, Rrjet Neural, pretendohet të jenë më të sakta se këto modele të zbatuara veçmas. Kështu që, në këtë kapitull do të prezantohen arkitekturat hibride ARIMA- ANN. Si një metodologji e re këto arkitektura janë zhvilluar dhe kanë marrë trajtën e plotë të tyre vetëm vitet e fundit. Modelet e njohura hibride ARIMA-ANN mund të ndahen në tri kategori sipas arkitekturës së hibridizimit:

- modele hibride në seri, ku fillohet modelimi me një metodë lineare dhe vazhdohet më një metodë jolineare.
- modele hibride në seri, ku fillohet modelimi me një metodë jolineare dhe vazhdohet më një metodë lineare.
- modele paralele, ku metoda lineare dhe jolineare zbatohen paralelisht, të pavarura nga njëra tjetra.

Literatura e modeleve hibride në seri për parashikimin e serive kohore është zgjeruar shumë që nga puna e hershme e Reid (1968). Arkitektura më e përdorur sot është

arkitektura e Zhang (2003). Ai niset nga supozimi se, seria kohore përbëhet nga të dyja komponentet, nga ajo lineare dhe jolineare. Parashikimi fillon me një metodë dhe kombinohet në vazhdimësi, me parashikimin e metodës me natyrë lineariteti të ndryshme nga e para. Në këtë lloj linje ka ecur edhe Pai & Lin (2005) të cilët krijuan një metodologji hibride për të parashikuar çmimin e aksioneve dhe treguan se, modeli hibrid në seri e tejkalonte performancën e komponenteve të përdorura veçmas. Një studim tjetër, ku tregohet qartë efikasiteti i parashikimit me anë të kombinimit të ARIMA me rrjetin neural me shumë shtresa, është kërkimi i Zeng *et. al.*, (2008). Rezultatet e eksperimentit për serinë kohore të trafikut vërtetuan se, modeli i propozuar hibrid përmirëson në mënyrë të dukshme saktësinë e parashikimit.

Pao (2009) propozoi një model hibrid në seri efikas që kombinonte rrjetin neural artificial dhe lloje të ndryshme të modeleve autoregresive. Wang, *et. al.*, (2013) propozuan një model hibrid, i cili është i veçantë në integrimin e përparësive të ARIMA dhe ANN në modelimin e sjelljeve lineare dhe jolineare, prezente në bashkësinë e të dhënave. Modeli hibrid u testua në tri seri kohore dhe rezultoi efikas duke dhënë parashikime më të sakta se modelet ekzistuese. Zhou *et. al.*, (2014) përdorën të njëjtën arkitekturë hibride në seri dhe treguan se, ky model kishte saktësi më të lartë parashikimi se sa përbërësit e tij të përdorur veçmas.

Të gjitha këto modele të propozuara kanë si bazë kombinimin e parashikimit në mënyrë të vazhduar, në seri, të një modeli linear ARIMA me një model jolinear, kryesisht ANN. Ndryshimi i arkitekturës së parë nga arkitektura e dytë qëndron në rendin e procesimit. Te arkitektura e kombinimit-1 puna fillon me model linear dhe vazhdon me parashikimin sipas modelit jolinear, ndërsa te arkitektura e kombinimit-2 rendi i procesimit është i kundërt, që do të thotë, fillon me modelimin jolinear dhe vazhdon me modelimin linear.

4.1 ARKITEKTURA E KOMBINIMIT-1

Në fazën e parë të arkitekturës së kombinimit 1, modeli ARIMA përdoret për të kapur komponentin linear. Shënohet me e_t mbetja e modelit ARIMA në kohën t , atëherë:

$$e_t = y_t - \hat{L}_t$$

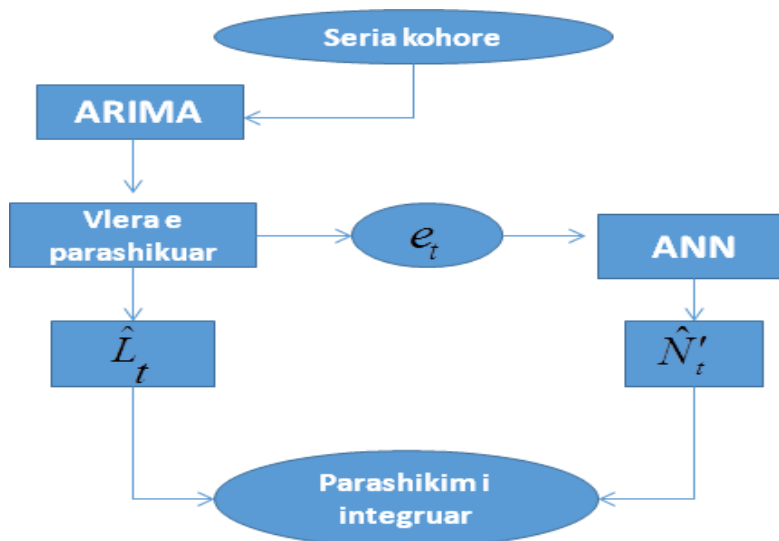
ku, \hat{L}_t është vlerë e parashikuar në kohën t e cila sigurohet nga modeli ARIMA.

Në fazën e dytë, nga modelimi i mbetjes duke përdorur ANN, mund të nxirren lidhjet jolineare. Me n neurone hyrëse, modeli ANN për mbetjet do të jetë:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \Rightarrow \hat{N}' = \hat{e}_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n})$$

ku, f është një funksion jolinear i përcaktuar nga modeli ANN, N' është vlerë e parashikuar në kohën t e cila vëzhgohet nga modeli ANN, ε_t është gabim i rastit.

Struktura e arkitekturës së kombinit 1 (Zhang, 2003) tregohet në figurën 10.



Figurë 10. Struktura e arkitekturës së kombinimit-1

Theksohet se, nëse modeli f është i papërshtatshëm termi i gabimit nuk është domosdoshmërisht i rastit. Ndaj, njohja e saktë e funksionit është kritike. Në këtë mënyrë, parashikimi i kombinuar do të jetë si më poshtë:

$$\hat{y}_t = \hat{L}_t + \hat{N}'$$

ku:

- \hat{y}_t është vlera e parashikuar nga modeli hibrid ARIMA-ANN në kohën t ;
- \hat{L}_t vlerë e parashikuar në kohën t e cila sigurohet nga modeli ARIMA,
- \hat{N}' është vlerë e parashikuar në kohën t e cila vëzhgohet nga modeli ANN (He & Deng, 2012).

Zhang (2003) e zbatoi këtë metodë në disa seri kohore dhe në të gjitha rastet rezultoi se, modeli hibrid jepte parashikime më të sakta se modelet ARIMA dhe ANN, të përdorura veçmas.

Ekziston një tjetër metodë hibride ARIMA-ANN, e ngjashme në arkitekturë me modelin e Zhang, me të vetmin ndryshim, parashikimet e secilës metodë nuk mblidhen, por shumëzohen (Wang, *et. al.*, 2013). Kjo ndodh sepse supozohet që, seria kohore është prodhim i një komponenteje lineare me një jolineare.

$$y_t = L_t \cdot N_t$$

Sërish, si te modeli Zhang, zbatohet si fillim metoda ARIMA mbi serinë origjinale dhe më pas metoda ANN mbi serinë që përftohet nga raporti i serisë kohore me vlerën e parashikuar nga modeli ARIMA.

$$n_t = \frac{y_t}{\hat{L}_t}$$

Si parashikim përfundimtar i sistemit, merret prodhimi i dy vlerave të parashikuara nga të dyja modelet veçmas.

$$\hat{y}_t = \hat{L}_t \cdot \hat{N}_t$$

Rezultatet treguan se, ky model është pothuajse në të njëjtat nivele efikasiteti si modeli i Zhang.

4.2 ARKITEKTURA E KOMBINIMIT-2

Arkitektura e kombinimit-2 ka gjithashtu dy faza kryesore. Në fazën e parë përdoret modeli ANN, në mënyrë që të modelojë pjesën jolineare të serive kohore.

$$\hat{N}_t$$

ku \hat{N}_t është vlera e parashikuar në kohën t e cila sigurohet nga modeli ANN.

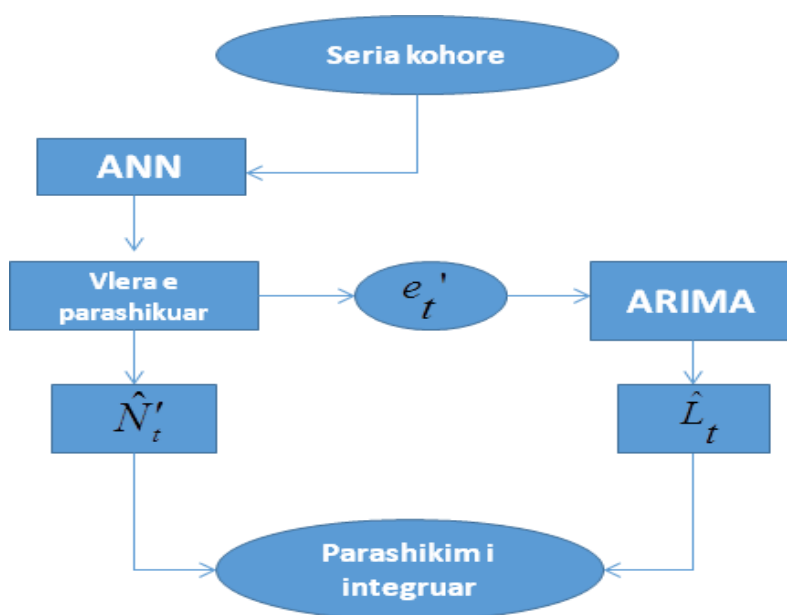
Kështu modeli ARIMA përdoret për të modeluar mbetjen e modelit ANN në mënyrë që të analizojë modelin linear. Në këtë mënyrë, modeli ARIMA me m intervale për mbetjet do të jetë :

$$e'_t = f(e'_{t-1}, e'_{t-2}, \dots, e'_{t-m}) + C_t \Rightarrow \hat{L}'_t = \hat{e}'_t = f(e'_{t-1}, e'_{t-2}, \dots, e'_{t-m})$$

ku,

- f është një funksion linear i përcaktuar nga ARIMA
- \hat{L}'_t është vlera e parashikuar për kohën t nga modeli ARIMA në të dhënat e tepricës
- C_t është gabim i rastit.

Struktura e modelit MLP-ARIMA (Xiong, *et. al.*, 2017) tregohet në figurën 11. Në këtë mënyrë, parashikimi i kombinuar do të jetë si më poshtë:



Figurë 11. Struktura e arkitekturës së kombinimit-2

4.3 ARKITEKTURA E KOMBINIMIT-3

Bates dhe Granger (1969) prezantuan konceptin e një kombinimi paralel të dy metodave, i cili u përdor më pas nga shumë studiues të tillë si Bunn (1989), Wedding & Cios (1996) të cilët propozuan një model paralel të kombinimit duke përdorur rrjetat me simetri rrethore dhe modelin Box-Jenkins ARIMA. Më pas, modelet parashikuese hibride të cilat kombinojnë në mënyrë paralele modelet lineare me modelet jolineare u shtuan. Wang *et. al.*, (2013) paraqiti një model hibrid paralel duke përdorur algoritmat gjenetik, ARIMA dhe rrjetat neurale me prapapërhapje. Rezultatet e tyre treguan se, modeli i propozuar i tejkalon në performancë të gjitha modelet e përdorura veçmas. Rather *et. al.*, (2015) për parashikimin e aksioneve në treg, propozuan një model të ri hibrid që bashkonte parashikimet e tri modeleve të veçanta: sheshimit eksponencial, rrjetit neural rekurent dhe ARIMA.

Peshat optimale të secilit model përcaktohen duke përdorur algoritmat gjenetikë. Yang *et. al.*, (2016) paraqitën një model parashikimi paralel duke kombinuar një rrjet neural me prapapërhapje, një rrjet përshtatës të bazuar në logjikën fuzzy dhe modelin SARIMA. Kështu përdoret një algoritëm metaheuristik i llogaritjes evolucionare për të optimizuar peshat e modelit hibrid. Studimet eksperimentale treguan se metoda e propozuar parashikoi më mirë se tri metodat individuale.

Në të gjitha këto modele parashikimi hibride, modelet ARIMA dhe ANN përdoren njëkohësisht, në mënyrë paralele, për të analizuar komponentët linear dhe jolinear të të dhënave dhe më pas merren dy rezultate parashikimi. Shuma e prodhimeve të koeficientëve optimal të peshës së çdo metode, me rezultatet përkatëse të parashikimit jep parashikimin përfundimtar të metodës hibride:

$$\hat{y}_t = \sum_{i=1}^m w_i \cdot f_i$$

Parashikimit në kohën t , m janë indekset e numërimit të modelit individual, w_i është pesha për metodën e i -të të parashikimit.

Gabimi i parashikimit llogaritet nëpërmjet ekuacionit:

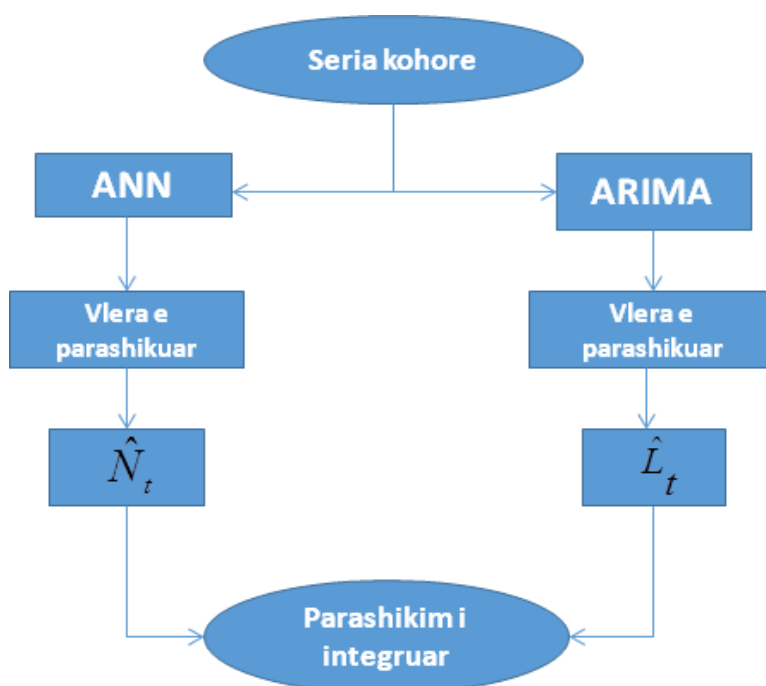
$$e_t = y_t - \hat{y}_t = y_t - \sum_{i=1}^m w_i \cdot f_i$$

Duke përdorur modelet ARIMA dhe ANN ekuacioni mund të rishkruhet si më poshtë:

$$\hat{y}_t = w_1 \cdot L_t + w_2 \cdot N_t$$

ku, \hat{y}_t , L_t dhe N_t janë, përkatësisht, vlera e parashikimit hibrid, e modelit ARIMA dhe ANN.

Për më tepër, peshat që i caktohen çdo modeli përcaktohen nga metoda e katrorëve më të vegjël dhe llogariten sipas ekuacioneve të mëposhtme.



Figurë 12. Struktura e arkitekturës së kombinimit-3

Një rast tjetër i po të njëjtës arkitekturë, do të ishte nëse natyra e jo/linearitetit do të njihet nëpërmjet filtrave të mesatares rrëshqitëse (Babu & Reddy, 2014).

Logjika e funksionimit të kësaj metode hibride bazohet në karakterizimin e natyrës së të dhënave e më pas në zbatimin e modeleve ARIMA dhe ANN në mënyrë të përshtatshme. Seria kohore, si filim, shpërbëhet nga përdorimi i filtrit të mesatares rrëshqitëse, e cila përdoret për të njohur natyrën e serisë dhe për të përdorur në mënyrë të saktë, pa hamendësime, modelin përkatës për çdo komponente.

Kështu, pasi nxirret komponentja lineare e serisë kalon në modelim me ARIMA dhe e njëjta gjë për komponenten jolineare që shkon për modelim sipas ANN. Në fund parashikimet e të dy modeleve integrohen në një parashikim të vetëm.

4.4 METODA E PROPOZUAR

Modelet e përmendura më sipër kanë të mirat dhe problemet e veta, sipas rastit të zbatimit. Performanca e modelit hibrid të Zhang shpesh herë është më e kënaqshme se çdo model përbërës i përdorur veçmas (Taskaya & Ahmad, 2005). Përveç kësaj, sigurohet se performanca e modelit hibrid të Zhang nuk do të jetë më keq se modeli ARIMA. Kjo mund të thuhet dhe për arkitekturat e tjera, të provuara nga studimet e mëparshme. Me gjithë përparësitë e përmendura të modeleve hibride, disa prej tyre, në sajë të supozimeve të marra si të mirëqëna, do të ulnin performancën e tyre nëse ndodhen në situata të kundërta.

Këto supozime janë:

Strukturat lineare dhe jolineare mund të modelohen veçmas nga modele të ndryshme dhe parashikimet e tyre mund të kombinohen në një të vetme. Komponentja lineare dhe jolineare mblidhen ose shumëzohen. Mbetjet e modelit linear përmbajnë vetëm strukturë jolineare, ose anasjelltas, mbetjet e modelit jolinear kanë vetëm strukturë lineare.

Ka raste që këto supozime nuk janë të vërteta, për shembull, nëse modelet ekzistuese lineare dhe jolineare në një seri kohore nuk mund të modelohen veçmas ose mbetjet e komponentit linear nuk përmbajnë vetëm strukturë jolineare ose komponentja lineare nuk është në marrëdhënie mbledhje apo shumëzimi me komponenten jolineare. Në këto raste, supozimet e marra mund të nënvlerësojnë marrëdhënien midis komponentëve dhe sjellin një degradim të performancës së modelimit dhe parashikimit.

Për këto arsye, në këtë studim propozohet një mënyrë tjetër hibridizimi e cila nuk nis me supozime. Sërish bazohet në kombinimin e ARIMA me ANN, ku fillimisht modelohet me ARIMA dhe vazhdohet me ANN. Kjo metodologji është e ngjashme me modelin Zhang në arkitekturë, me ndryshimin se ANN nuk modelon vetëm sekuencën e mbetjeve nga modeli ARIMA, por të gjithë komponentët e serisë origjinale. Këto komponentë merren nga zbatimi i metodës ARIMA mbi serinë kohore. Nga ky modelim përftohen termat autoregresiv, termat e mesatares rrëshqitëse dhe mbetjet.

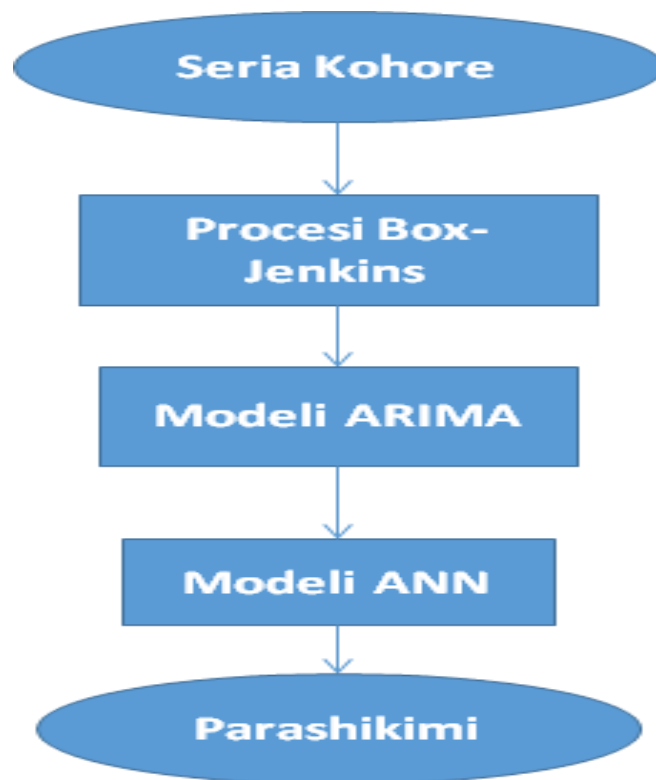
Të gjitha këto përdoren si hyrje në rrjetin neural. Në këtë formë përcaktohet në mënyrë korrekte dhe të qartë numri i neuroneve hyrëse, një punë e cila do të kryhej në mënyrë të rastësishme ose me anë të metodës 'provo dhe vlerëso gabimin'. Këtu, numri i vonesave në kohë që shërbejnë si hyrje përcaktohet nga termat që ndikojnë drejtpërdrejtë në modelim dhe më pas në parashikim. Rrjeti neural, si një përafrues universal (Hornik *et. al.*, 1989), me këto hyrje do të jetë në gjendje në sajë të procesit të trajnimit të përafrojtë modelin e serisë kohore.

Vlera e ardhshme e një serie kohore, te rrjeti neural, konsiderohet si funksion jolinear i disa vrojtimeve të kaluara dhe gabimeve të rastit si më poshtë:

$$\hat{y}_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-m}, e_{t-1}, e_{t-2}, \dots, e_{t-l})$$

ku:

- f është një funksion jolinear i përcaktuar nga rrjeti neural;
- e_t është mbetja e modelit ARIMA në kohën t ;
- m dhe l janë numra të plotë. Pra, ky rrjet neural modelon dhe pjesën lineare dhe komponenten jolineare të serisë kohore. Arkitektura e tij jepet në figurën e mëposhtme.



Figurë 13. Arkitektura e modelit të propozuar Hibrid ARIMA-ANN

KAPITULLI 5

METODOLOGJIA

Qëllimi i këtij studimi është ndërtimi i një modeli të përmirësuar për parashikimin e serive kohore, përmes kombinimit të metodave tradicionale statistikore dhe teknologjive moderne të inteligjencës artificiale. Për këtë arsye, janë përzgjedhur katër raste konkrete studimi nga fusha të ndryshme (ekonomi, financë, arsim dhe motivim profesional), të cilat trajtohen si seri kohore të veçanta dhe krahasohen nëpërmjet tre qasjeve: modeli ARIMA, rrjetet neurale artificiale (ANN) dhe modeli hibrid ARIMA-ANN. Më poshtë jepet një tabelë përmbledhëse në lidhje me metodologjinë e punimit.

Tabelë 2. Përmbledhëse e metodologjisë për raste studimore

Rasti Studimi	Lloji i të Dhënave	Burimi	Metoda ARIMA	Metoda ANN	Modeli Hibrid
Kursi i këmbimit Euro/Lek	Ditore	Banka e Shqipërisë	E përshtatshme për tendenca lineare	Korrigjon devijimet jolineare	Saktësi më e lartë sesa ARIMA/ANN veçmas
Çmimi ditor i Bitcoin-it	Ditore	Coin Market Cap	Pak efektive për luhatje të mëdha	Shumë efektive për jostabilitet	Performanca më e mirë globale
Rezultatet e provimeve të maturës	Vjetore	Ministria e Arsimit	E përshtatshme për analiza statistikore	Kap ndërlikimet politike/arsimore	Kombinon avantazhet e të dy metodave
Motivimi i lektorëve	Mujore	Anketim empirik	Performancë mesatare	Adaptim i mirë ndaj të dhënave subjektive	Përmirësim i qartë në parashikime mujore

Tabela përmbledhëse e metodologjisë për rastet studimore paraqet në mënyrë sintetike dhe krahasuese qasjen analitike të ndjekur në këtë studim për katër seri kohore me rëndësi të veçantë për kontekstin socio-ekonomik dhe arsimor shqiptar. Këto raste përfshijnë kursin e këmbimit Euro/Lek, çmimin ditor të Bitcoin-it, rezultatet e provimeve të maturës shtetërore dhe nivelin e motivimit të lektorëve në Fakultetin e Inxhinierisë. Për secilin prej këtyre rasteve janë analizuar disa elementë kyç si lloji i të dhënave (p.sh. ditore, mujore apo vjetore), burimi zyrtar i të dhënave, efikasiteti i metodës tradicionale ARIMA, performanca e rrjeteve neurale artificiale (ANN) si dhe vlera e shtuar që sjell modeli hibrid ARIMA-ANN.

Në rastin e kursit të këmbimit Euro/Lek, që përfaqëson një seri ditore të dhënash me rëndësi për stabilitetin monetar, metoda ARIMA ka ofruar një përputhje të mirë me prirjet lineare, por modelet ANN kanë qenë më të suksesshme në identifikimin e

luhatjeve jolineare të papritura, ndërkohë që modeli hibrid ka rezultuar më i saktë në përgjithësi. Për çmimin ditor të Bitcoin-it, një treg i njohur për volatilitetin e lartë, metoda ARIMA është treguar më pak efektive, ndërsa rrjetet neurale kanë arritur të përshtaten më mirë me sjelljen e paparashikueshme të kësaj serie, me modelin hibrid që tejkalon të dy alternativat në aspektin e saktësisë. Në analizën e rezultateve të provimeve të maturës shtetërore, të cilat janë të dhëna vjetore me ndikime të mundshme nga politika arsimore dhe faktorë të tjerë socio-kulturorë, metoda ARIMA është përdorur për të identifikuar trendet bazë, ndërsa rrjetet ANN kanë mundësuar të kapen ndërlikimet në sipërfaqe dhe modeli hibrid ka shfaqur një potencial të veçantë për të bërë parashikime më të sakta dhe të dobishme për politikëbërësit në fushën e arsimit.

Rasti i fundit, motivimi i lektorëve në Fakultetin e Inxhinierisë, i bazuar në të dhëna mujore të mbledhura nëpërmjet anketimit empirik, përfaqëson një shembull të modelimit të një fenomeni subjektiv, ku rrjetet ANN janë përshtatur më mirë me natyrën cilësore të të dhënave në krahasim me metodën ARIMA, dhe përdorimi i modelit hibrid ka ndihmuar në përmirësimin e parashikimeve mbi tendencat e motivimit në kohë. Në të gjitha rastet e analizuar, modeli hibrid ARIMA-ANN ka dalë në pah si një alternativë më e qëndrueshme dhe më e saktë për parashikimin e serive kohore, duke kombinuar fuqinë shpjeguese të modeleve lineare me fleksibilitetin dhe fuqinë përfaqësuese të rrjeteve neurale, çka përforcon tezën se hibridizimi i metodave është një qasje efikase për përballimin e sfidave që paraqet parashikimi në të dhënat reale.

5.1 PËRZGJEDHJA E RASTEVE TË STUDIMIT DHE BURIMET E TË DHËNAVE

Të dhënat janë marrë nga burime të besueshme si:

- *INSTAT* për të dhënat demografike dhe arsimit, <https://www.instat.gov.al/>
- *Banka e Shqipërisë* për kursin e këmbimit, <https://share.google/Wjs3lOveXVx2xanN2>
- *Coin Market Cap* për të dhënat e Bitcoin-it, <https://share.google/5SSwgjJEuuAEu3EkI>
- *Ministria e Arsimit* për rezultatet e maturës shtetërore, www.qsha.edu.al

Sondazh empirik i ndërtuar për këtë studim për të matur motivimin e lektorëve në fakultetin e inxhinierisë. Përzgjedhja e rasteve të studimit dhe burimet e të dhënave, përbëjnë një komponent kyç të strukturës metodologjike të këtij kërkimi, pasi garanton besueshmërinë dhe cilësinë e analizave të mëvonshme. Raste të ndryshme janë zgjedhur në mënyrë të qëllimshme për të përfaqësuar fusha të ndryshme me rëndësi të veçantë për zhvillimin ekonomik, financiar dhe arsimor në Shqipëri. Këto raste përfshijnë kursin e këmbimit Euro/Lek, çmimin ditor të Bitcoin-it, rezultatet e provimeve të maturës shtetërore si dhe nivelin e motivimit të lektorëve në Fakultetin e Inxhinierisë.

Të dhënat për secilin rast janë marrë nga burime të besueshme dhe të verifikuara, të cilat ofrojnë siguri në saktësinë dhe konsistencën e tyre. Konkretisht, për të dhënat demografike dhe treguesit arsimorë është përdorur Instituti i Statistikave (INSTAT), institucioni zyrtar që mbledh dhe publikon të dhëna statistikore për Shqipërinë. Kursi i këmbimit Euro/Lek është marrë nga Banka e Shqipërisë, e cila garanton përditësim të rregullt dhe saktësi të të dhënave financiare.

Për çmimin ditor të Bitcoin-it, një treg global që karakterizohet nga luhatje të vazhdueshme, është përdorur platforma ndërkombëtare Coin Market Cap, e cila konsiderohet një nga burimet më të sakta dhe të aksesueshme për të dhënat e kriptomonedhave në kohë reale. Ndërkohë, rezultatet e provimeve të maturës shtetërore janë marrë nga Ministria e Arsimit, që publikon çdo vit statistikat përfundimtare për performancën e nxënësve në nivel kombëtar. Në rastin e motivimit të lektorëve, të dhënat nuk janë marrë nga një burim ekzistues zyrtar, por janë grumbulluar përmes një sondazhi të ndërtuar posaçërisht për këtë studim, duke përdorur metoda të kërkimit empirik për të matur perceptimin dhe ndjeshmërinë individuale të stafit akademik në raport me faktorët që ndikojnë në motivimin profesional. Kjo qasje e kombinuar e burimeve zyrtare dhe instrumenteve të ndërtuara enkas për këtë studim siguron një bazë të gjerë dhe të shumëllojshme të të dhënave që mbështet realizimin e analizës së thelluar me metoda të inteligjencës artificiale dhe modeleve të parashikimit të serive kohore.

5.2 RASTET E STUDIMIT DHE TRAJTIMI METODOLOGJIK

5.2.1 KURSI I KËMBIMIT EURO/LEK

Në kuadër të studimit mbi analizën dhe parashikimin e serive kohore përmes modeleve të inteligjencës artificiale, rasti i kursit të këmbimit Euro/Lek zë një vend të rëndësishëm për shkak të ndikimit të drejtpërdrejtë që ky indikator ka në ekonominë shqiptare, sidomos në marrëdhëniet tregtare ndërkombëtare, politikat monetare dhe vendimmarrjen financiare të bizneseve dhe individëve. Seria e përdorur në këtë rast përbëhet nga të dhëna ditore të kursit zyrtar të këmbimit, të publikuara nga Banka e Shqipërisë dhe që shtrihen përgjatë një periudhe të gjatë kohore, duke siguruar kështu densitet të mjaftueshëm të të dhënave për ndërtimin e modeleve statistikore dhe inteligjente.

Fillimisht, seria kohore është analizuar në aspektin e saj strukturor, duke shqyrtuar karakteristikat e stacionaritetit, autokorelacionit dhe sezonalitetit, në mënyrë që të përzgjidhet modeli më i përshtatshëm ARIMA për trajtimin e komponentëve linearë. Pas përshtatjes së modelit klasik ARIMA dhe vlerësimit të mbetjeve të modelit, është vërejtur se disa luhatje jolineare nuk adresoheshin plotësisht, duke sugjeruar nevojën për një model shtesë që të kapë kompleksitetin jo-linear të sjelljes së kursit të këmbimit. Për këtë arsye, është ndërtuar dhe trajnuar një model i Rrjetit Neural Artificial (ANN), i cili është trajnuar mbi të njëjtat të dhëna, por duke marrë si hyrje mbetjet e modelit ARIMA.

Kjo qasje i mundëson rrjetit neural të përqendrohet në aspektet e sjelljes së serisë që nuk mund të përshkruhen nga modelet lineare tradicionale. Më pas, është ndërtuar një model hibrid ARIMA-ANN, ku rezultati përfundimtar përbëhet nga kombinimi i parashikimit të modelit ARIMA me atë të rrjetit ANN, duke marrë parasysh si komponentët linearë ashtu edhe ata jolinearë. Performanca e këtij modeli hibrid është matur përmes treguesve të saktësisë si RMSE (Root Mean Square Error) dhe MAE (Mean Absolute Error), të cilët japin një vlerësim të qartë të gabimit mesatar dhe variacionit të tij.

Rezultatet kanë treguar se modeli hibrid ARIMA-ANN e tejkalon ndjeshëm modelin tradicional ARIMA dhe atë neural ANN të përdorur në mënyrë të ndarë, duke ofruar një mjet më të fuqishëm për parashikimin e tendencave të kursit të këmbimit në Shqipëri. Kjo qasje metodologjike jo vetëm që pasuron analizën me dimensione të reja teknike, por gjithashtu i jep vlerë praktike kërkimit në fushën e ekonomisë dhe financave, veçanërisht për politikëbërësit, ekonomistët dhe agjentët e tregut të valutës.

5.2.2 ÇMIMI DITOR I BITCOIN-IT

Si një kriptomonedhë që operon në tregje të hapura dhe të decentralizuara, çmimi i Bitcoin-it ndikohet nga një sërë faktorësh kompleksë, përfshirë perceptimet e tregut, lajmet globale, ndërhyrjet rregullatore, spekulimet dhe mungesa e mbështetjes nga një institucion qendror. Të dhënat janë marrë nga platformat më të besueshme ndërkombëtare të monitorimit të kriptomonedhave, si Coin Market Cap, të cilat ofrojnë informacion të detajuar dhe në kohë reale për çmimet e tregut.

Fillimisht, për këtë seri kohore është ndërtuar modeli ARIMA, duke ndjekur të njëjtin proces analitik si në rastin e kursit të këmbimit: analiza e stacionaritetit, identifikimi i parametrave dhe kalibrimi i modelit. Megjithatë, për shkak të luhatjeve ekstreme dhe sjelljes tepër jolineare të serisë, modeli ARIMA nuk ka arritur të kapë me saktësi strukturën e brendshme të të dhënave, duke prodhuar parashikime me saktësi të kufizuar. Për të përmirësuar performancën e analizës, është aplikuar modeli i rrjeteve neurale artificiale (ANN), i cili është ndërtuar dhe trajnuar mbi të njëjtat të dhëna, duke e lejuar atë të identifikojë modelet jolineare dhe të përvetësojë luhatjet e papitura në mënyrë më efikase. Rezultatet nga modeli ANN kanë treguar një përmirësim të ndjeshëm në krahasim me modelin ARIMA, veçanërisht në parashikimet afatshkurtra, ku fleksibiliteti i rrjetit neural i mundëson atij të përshtatet shpejt ndaj ndryshimeve të tregut. Më tej, është ndërtuar një model hibrid ARIMA-ANN, ku parashikimi përfundimtar është rezultat i integritit të komponentëve linearë të kapur nga ARIMA dhe atyre jolinearë të përpunuar nga ANN.

Ky model hibrid është testuar dhe vlerësuar përmes treguesve të performancës RMSE dhe MAE, dhe ka rezultuar të jetë ndjeshëm më i saktë në parashikimin afatshkurtër të çmimit të Bitcoin-it sesa secili nga modelet e përdorur veçmas. Aftësia e modelit hibrid për të kapur kompleksitetin dinamik të tregut të kriptomonedhave e bën atë një mjet të

dobishëm për investitorët, analistët financiarë dhe studiuesit që kërkojnë të kuptojnë dhe parashikojnë sjelljen e këtij tregu. Për më tepër, ky rast vërteton fuqinë e metodave hibride në përballjen me seri kohore me luhatshmëri ekstreme dhe karakteristika jolineare, duke forcuar bindjen se integrimi i qasjeve sasiore dhe inteligjente është thelbësor në kontekste të tilla.

5.2.3 REZULTATET E PROVIMEVE TË MATURËS SHETËTËRORE

Në seksionin që trajton analizën e rezultateve të provimeve të maturës shetëtare, fokusi vendoset në një fushë thelbësore për zhvillimin arsimor dhe shoqëror të vendit, ku performanca e nxënësve në lëndë bazë si matematika dhe gjuha shqipe shërben si indikator kyç për vlerësimin e cilësisë së sistemit arsimor. Ky rast studimor ka rëndësi të veçantë për politikëbërësit në arsim, për institucionet e edukimit dhe për shoqërinë në tërësi, pasi rezultatet e maturës reflektojnë jo vetëm nivelin e përvetësimit të njohurive nga nxënësit, por edhe ndikimin e politikave mësimore, metodave pedagogjike, kushteve sociale dhe teknologjike në arsim. Të dhënat e përdorura janë marrë nga Ministria e Arsimit dhe përfaqësojnë rezultate zyrtare të grumbulluara në nivel kombëtar për një periudhë të caktuar vitesh, duke mundësuar ndërtimin e një serie kohore vjetore me qëllim analizimin e tendencave dhe parashikimin e ecurisë së ardhshme.

Fillimisht, seria kohore është analizuar duke aplikuar modelin ARIMA për të identifikuar strukturën lineare të ndryshimeve nga viti në vit dhe për të kuptuar nëse ka një rritje, ulje apo stabilitet në rezultatet e përgjithshme. Megjithatë, për shkak të faktorëve të shumtë që ndikojnë në rezultatet e provimeve – si ndryshimet në programet mësimore, ndryshimet në strukturën e testit, ndikimet psikologjike dhe faktorët socio-ekonomikë – sjellja e të dhënave shpesh shfaq devijime dhe luhatje të paparashikuara që modelet lineare nuk arrijnë t'i kapin plotësisht.

Për këtë arsye, është aplikuar më tej modeli i rrjeteve neurale artificiale (ANN), i cili është ndërtuar dhe trajnuar mbi të njëjtat të dhëna për të përpunuar struktura më komplekse dhe jolineare. Rezultatet nga modeli ANN kanë treguar saktësi më të lartë në parashikimin e ndryshimeve të papritura në rezultatet e maturës, veçanërisht në identifikimin e vit-pas-viti devijimeve të cilat lidhen me ndërhyrje sistematike në sistemin arsimor. Në fazën e tretë të trajtimit metodologjik, është zhvilluar dhe testuar një model hibrid ARIMA-ANN, i cili kombinon fuqinë e modelit ARIMA në kapjen e tendencave lineare me aftësinë e ANN për të trajtuar variacionet jolineare dhe komplekse. Ky model hibrid është testuar përmes indikatorëve të performancës si RMSE dhe MAE dhe ka rezultuar më i qëndrueshëm në prodhimin e parashikimeve më afër realitetit krahasuar me modelet individuale.

Avantazhi i këtij modeli qëndron në balancimin e gabimeve të parashikimit dhe në rritjen e besueshmërisë së rezultateve, duke ofruar një mjet të vlefshëm për institucionet arsimore dhe studiuesit që synojnë të kuptojnë dhe parashikojnë më mirë faktorët që

ndikojnë në suksesin shkollor. Kështu, rasti i rezultateve të maturës shtetërore jo vetëm që tregon aplikueshmërinë e metodave hibride në fushën e arsimit, por gjithashtu demonstroi rëndësinë e përdorimit të analizës së avancuar të të dhënave për përmirësimin e planifikimit arsimor dhe hartimin e politikave të orientuara drejt rezultateve më të mira për brezat e ardhshëm të nxënësve.

5.2.4 MOTIVIMI I LEKTORËVE NË FAKULTETIN E INXHINIERISË

Në trajtimin e rastit të katërt, që lidhet me analizën e motivimit të lektorëve në fakultetin e inxhinierisë, studimi zgjeron fushën e aplikimit të metodave të parashikimit përtej treguesve ekonomikë dhe financiarë, duke përfshirë edhe indikatorë të performancës dhe mirëqenies në sektorin e arsimit të lartë. Ky rast fokusohet në matjen dhe analizimin e perceptimeve të stafit akademik lidhur me nivelin e motivimit të tyre profesional, një aspekt kyç që ndikon drejtpërdrejt në cilësinë e mësimdhënies, angazhimin kërkimor dhe atmosferën institucionale. Të dhënat janë mbledhur përmes një sondazhi të strukturuar dhe të standardizuar, i cili është zhvilluar enkas për këtë studim, duke u administruar çdo muaj përgjatë një periudhe dyvjeçare. Kjo ka mundësuar krijimin e një serie kohore mujore, të pasur në informacion dhe e përshtatshme për analizë statistikore dhe modelim të avancuar.

Ndryshe nga rastet e tjera që trajtojnë të dhëna të natyrës objektive dhe të standardizuar, të dhënat e lidhura me motivimin janë në thelb subjektive, pasi burojnë nga vlerësime individuale dhe ndjesi personale, të cilat ndikohen nga faktorë të shumtë si ngarkesa e punës, marrëdhëniet institucionale, shpërblimi financiar, mundësitë për zhvillim profesional dhe mbështetja administrative. Për këtë arsye, seria kohore e krijuar nga këto të dhëna përmban elementë të theksuar jolineariteti dhe variabiliteti të paparashikueshëm, që shpesh nuk mund të kapen me efektivitet nga modelet tradicionale lineare si ARIMA. Megjithatë, edhe në këtë rast, për qëllime krahasimore, është ndërtuar modeli ARIMA duke analizuar nëse ekzistojnë komponentë trendi apo sezonaliteti që mund të modelohen në mënyrë lineare. Rezultatet nga ARIMA kanë treguar një kapacitet të kufizuar për të reflektuar kompleksitetin emocional dhe dinamikën e perceptimeve të stafit akademik.

Për të trajtuar më saktë këtë kompleksitet, është ndërtuar dhe trajnuar një model i rrjeteve neurale artificiale (ANN), i cili, falë aftësisë së tij për të mësuar nga të dhënat dhe për të përpunuar marrëdhënie jolineare ndërmjet variablave, ka arritur të prodhojë parashikime më realiste të luhatjeve të motivimit. Rrjeti neural është trajnuar mbi një sërë indikatorësh të përfshirë në sondazh, përfshirë pyetje mbi ndjesinë e vlerësimit profesional, besimin në menaxhimin akademik dhe balancën punë-jetë. Më tej, është ndërtuar modeli hibrid ARIMA-ANN, i cili kombinon qasjen lineare të ARIMA me fleksibilitetin jolinear të ANN.

Ky model ka ofruar një pamje më të thelluar dhe të integruar të faktorëve që ndikojnë në uljen apo rritjen e motivimit profesional në kohë, duke e bërë të mundur jo vetëm

parashikimin, por edhe identifikimin e periudhave kritike kur ndërhyrjet menaxheriale janë të nevojshme. Performanca e modeleve është vlerësuar me anë të indikatorëve si RMSE dhe MAE, të cilët konfirmuan superioritetin e modelit hibrid në krahasim me modelet individuale.

Rasti i motivimit të lektorëve dëshmon qartë se analiza dhe parashikimi i faktorëve njerëzorë kërkon qasje të sofistikuar metodologjike që integrojnë statistikat tradicionale me inteligjencën artificiale. Ai gjithashtu vë në pah mundësinë e përdorimit të teknologjive të avancuara për të përmirësuar menaxhimin e burimeve njerëzore në arsimin e lartë, duke i mundësuar institucioneve të identifikojnë me kohë problematikat dhe të ndërmarrin masa të synuara për rritjen e mirëqenies së stafit dhe përmirësimin e performancës institucionale.

5.3 ZBATIMI TEKNIK DHE VLERËSIMI I PERFORMANCËS

Për të gjitha rastet, janë ndjekur këto hapa metodologjikë:

- *Analiza e karakteristikave statistikore të secilës seri kohore.*
- *Ndërtimi i modelit ARIMA, për trajtimin e komponentëve linearë.*
- *Zhvillimi i modelit ANN, për të trajtuar pjesët jolineare.*
- *Ndërtimi i modelit hibrid ARIMA-ANN dhe krahasimi me modelet individuale.*
- *Vlerësimi i performancës, përmes treguesve RMSE, MAE, MAPE, MPE dhe U i Theil-it.*
- *Visualizimi i rezultateve, nëpërmjet grafikëve krahasues dhe analizës së gabimit.*

Procesi ka filluar me analizën statistikore të karakteristikave të secilës seri kohore, përfshirë testet e stacionaritetit si testi Augmented Dickey-Fuller (ADF), vlerësimin e sezonalitetit dhe identifikimin e prirjeve ose anomalive në të dhëna. Kjo fazë fillestare është thelbësore për të përcaktuar natyrën e të dhënave dhe për të zgjedhur qasjen më të përshtatshme për modelimin.

Më pas, është ndërtuar modeli ARIMA (AutoRegressive Integrated Moving Average) për secilën seri kohore. Ky model synon të kapë komponentët linearë të serisë, duke përfshirë pjesën autoregresive (AR), pjesën e integruar që trajton trendin e të dhënave (I), dhe pjesën e lëvizjes mesatare (MA). Në këtë hap, është bërë përzgjedhja optimale e parametrave (p, d, q) përmes analizës së funksioneve të autokorrelacionit (ACF²⁹) dhe autokorrelacionit të pjesshëm (PACF³⁰), si dhe janë testuar disa variante të modelit për të identifikuar atë që jep performancën më të mirë në bazë të kriterëve të informacionit si AIC dhe BIC.

Pasi janë ndërtuar modelet lineare, për të kapur pjesën jolineare të të dhënave, është zhvilluar modeli i rrjeteve neurale artificiale (ANN). Ky model është trajnuar mbi të

²⁹ AutoCorrelation Function

³⁰ Partial AutoCorrelation Function

njëjtën seri kohore duke përdorur struktura të ndryshme të rrjetit (numri i shtresave dhe neuroneve të fshehura), funksione aktivizimi dhe algoritme trajnimi si backpropagation. Qëllimi kryesor i kësaj faze ka qenë trajtimi i modeleve komplekse të të dhënave që nuk mund të modelohen përmes metodave tradicionale lineare. Në disa raste, modeli ANN ka treguar saktësi më të lartë në parashikimet afatshkurtra dhe është përdorur për të eksploruar marrëdhënie të ndërlikuara që mund të mos jenë të dukshme në mënyrë të drejtpërdrejtë.

Në hapin pasues, është ndërtuar një model hibrid ARIMA-ANN, që synon të kombinojë përparësitë e të dy modeleve të mësipërme. Fillimisht, ARIMA përdoret për të modeluar dhe larguar komponentët linearë nga seria kohore. Pastaj, mbetjet (residues) e modelit ARIMA, që përfaqësojnë strukturat jolineare të mbetura, modelohen përmes rrjetit neural ANN. Parashikimi përfundimtar përfitohet duke kombinuar rezultatet e të dy modeleve. Ky model hibrid është provuar veçanërisht efektiv në rastet kur seria kohore përmban si komponentë linearë ashtu edhe jolinearë, duke sjellë një përmirësim të ndjeshëm në performancën e përgjithshme të parashikimit. Vlerësimi i performancës së modeleve është kryer përmes një sërë treguesish statistikore, përfshirë:

Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Mean Percentage Error (MPE) dhe Theil's U statistic.

Këta indikatorë japin një pasqyrë të plotë mbi gabimin mesatar të parashikimeve, përqindjen e devijimeve dhe aftësinë relative të modelit për të ofruar një parashikim të besueshëm krahasuar me modele naive. Performanca është analizuar jo vetëm në aspektin e saktësisë numerike, por edhe në qëndrueshmërinë e modelit ndaj variacioneve të të dhënave.

Më në fund, të gjitha rezultatet janë vizualizuar përmes grafikëve krahasues, të cilët paraqesin diferencat midis vlerave reale dhe atyre të parashikuara nga secili model. Këta grafikë ndihmojnë në identifikimin vizual të performancës së modeleve dhe në analizimin e mënyrës se si secili model reagon ndaj ndryshimeve të papritura në të dhëna. Për më tepër, është bërë analiza e gabimeve (residual analysis) për të kontrolluar nëse mbetjet janë të shpërndara në mënyrë të rastësishme dhe nëse ekziston ndonjë strukturë e pamodeluar, gjë që do të sugjeronte nevojën për modifikim të mëtejshëm të modelit. Kështu, kjo qasje gjithëpërfshirëse metodologjike e bën të mundur jo vetëm ndërtimin e modeleve të sakta, por edhe vlerësimin e thelluar të efikasitetit të tyre në kontekste të ndryshme të të dhënave.

5.4 NDARJA E TË DHËNAVE PËR TRAJNIM, VALIDIM DHE TESTIM

Procesi i ndarjes së të dhënave përbën një komponent thelbësor të metodologjisë së këtij studimi, pasi siguron vlerësimin objektiv të aftësisë së përgjithshme të modeleve për të generalizuar në të dhëna të reja. Për secilin rast studimor është kryer një ndarje kronologjike në tri pjesë: *seti i trajnimit* (training set), *seti i validimit* (validation set)

dhe *seti i testim* (testing set). Kjo qasje është përdorur për të shmangur përzierjen e periudhave kohore dhe për të respektuar integritetin kronologjik të serive kohore, duke garantuar që çdo model të mësojë vetëm nga e kaluara dhe të testojë performancën në të ardhmen e panjohur.

Rasti 1: Çmimi ditor i Bitcoin-it

Për rastin e çmimit të Bitcoin-it, i cili përfshin një total prej 1405 ditësh të dhënash ditore, ndarja është realizuar në 953 ditë për trajnim, 422 ditë për validim, dhe 30 ditë për testim. Kjo ndarje përfaqëson afërsisht raportin 68%–30%–2%, dhe është projektuar për të siguruar që modeli të mësojë mbi një bazë të gjerë të dhënash historike, të rregullojë parametrat përmes procesit të validimit dhe të testojë saktësinë përfundimtare mbi një periudhë të shkurtër të pavarur. Natyra e luhatshme e tregut të kriptomonedhave kërkon kujdes të veçantë në ndarjen kohore, pasi çdo përzierje e të dhënave do të ndikonte në besueshmërinë e parashikimeve. Për rrjedhojë, ndarja kronologjike e pandërprerë siguron integritetin e procesit të testimi dhe mundëson krahasime të drejta ndërmjet modeleve ARIMA, ANN dhe hibridit ARIMA–ANN.

Rasti 2: Rezultatet e Maturës Shtetërore

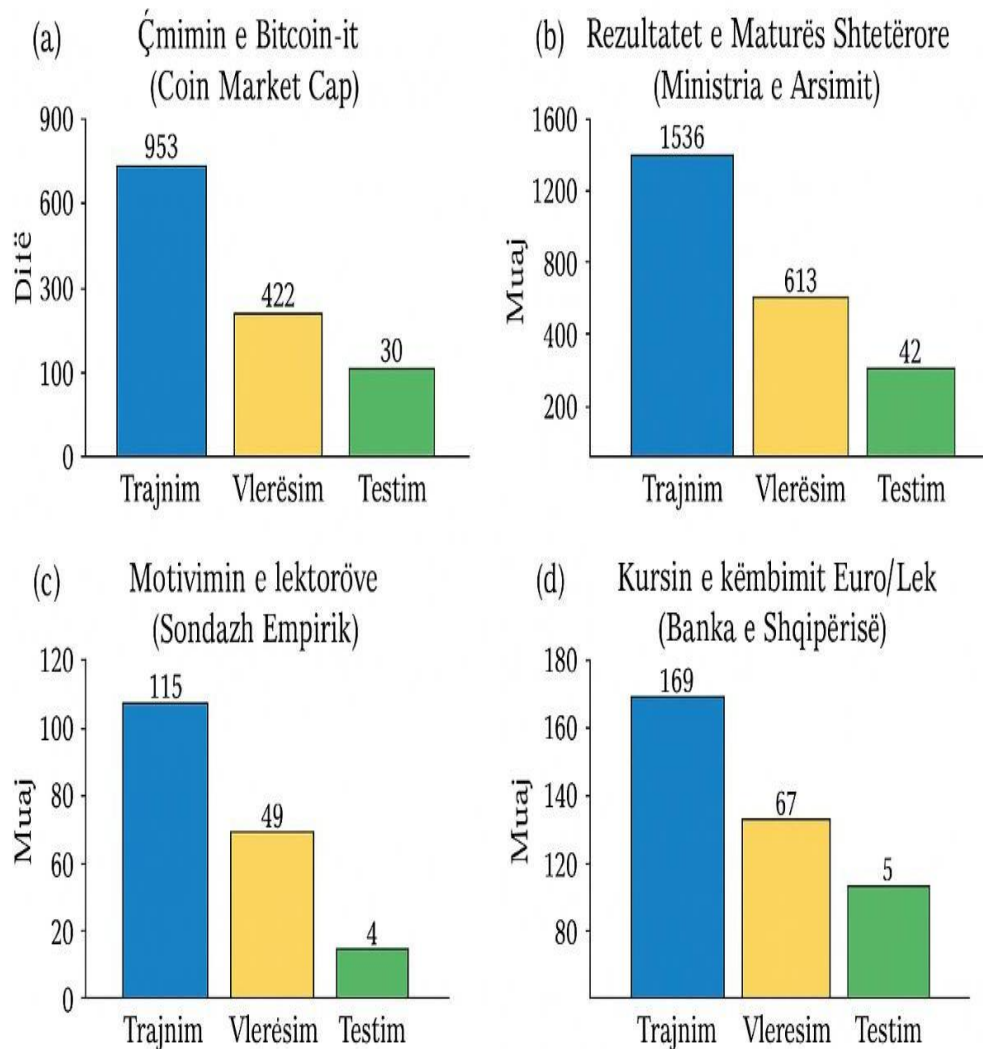
Në rastin e rezultateve të maturës shtetërore, të cilat përfaqësojnë një total prej 2191 ditësh të dhënash vjetore të përpunuara në format të unifikuar kohor, ndarja është bërë si vijon: 1536 ditë për trajnimin e modelit, 613 ditë për validim dhe 42 ditë për testim. Kjo ndarje pasqyron një shpërndarje të balancuar që i mundëson modelit të mësojë tendencat afatgjata të performancës së nxënësve, të kalibrojë parametrat përmes validimit dhe të testojë saktësinë mbi një periudhë të fundit për të vlerësuar aftësinë e modelit për të parashikuar rezultatet e ardhshme. Në këtë rast, është respektuar gjithashtu rendi kronologjik i të dhënave, duke garantuar që parashikimet të mos ndikohen nga informacioni i ardhshëm, dhe se procesi i testimi reflekton sjelljen reale të modelit në parashikime të reja.

Rasti 3: Motivimi i lektorëve në Fakultetet e Inxhinierisë

Për serinë kohore mujore që përfaqëson motivimin e lektorëve, janë përpunuar gjithsej 168 muaj të dhënash, të cilat janë ndarë në 115 muaj për trajnim, 49 muaj për validim, dhe 4 muaj për testim. Duke qenë se bëhet fjalë për të dhëna të mbledhura përmes sondazhit empirik, me karakter të ndjeshëm dhe subjektiv, kjo ndarje është kryer me kujdes për të ruajtur balancën ndërmjet periudhave të ndryshme akademike, si dhe për të siguruar që procesi i trajnimit të përfshijë ciklet sezonale të ndryshme të aktivitetit universitar. Seti i validimit është përdorur për të përshtatur strukturën optimale të rrjetit neural, ndërsa periudha e testimi është shfrytëzuar për të vlerësuar saktësinë e parashikimeve mbi të dhëna reale të pavarura. Kjo strategji ndarjeje ka ndihmuar në matjen e qëndrueshmërisë së modeleve ndaj ndryshimeve të sjelljes njerëzore dhe faktorëve organizativë që ndikojnë në motivimin profesional.

Rasti 4: Kursi i këmbimit Euro/Lek

Për serinë kohore të kursit të këmbimit Euro/Lek, e cila përfshin gjithsej 241 muaj të



dhënash, u krye një ndarje e strukturuar si më poshtë: 169 muaj u përdorën për trajnimin e modelit, 67 muaj për validim, dhe 5 muaj për testim përfundimtar. Ndarja u krye në mënyrë kronologjike, duke filluar nga periudhat më të hershme për trajnimin e modeleve ARIMA, ANN dhe modelit hibrid ARIMA–ANN, ndërsa periudhat më të fundit u rezervuan për vlerësim dhe testim të performancës. Ky konfigurim siguron që modeli të përvetësojë karakteristikat lineare dhe jolineare të serisë pa u ekspozuar ndaj të dhënave të ardhshme, duke mundësuar një vlerësim realist të aftësisë së tij parashikuese.

Figurë 14. Tregon ndarjen e të dhënave për: a) çmimin e Bitcoin-it, b) rezultatet e Maturës Shtetërore, c) motivimin e lektorëve, d) kursin e këmbimit Euro/Lek

KAPITULLI 6

REZULTATET E PUNIMIT

Gershenfeld dhe Weigend (1994) pohuan se analiza e serisë kohore ka tri qëllime kryesore: karakterizimin, modelimin dhe parashikimin. Për zhvillimin e këtyre hapave në rastin e kursit të këmbimit Euro/Lek, çmimit ditor të Bitcoin-it, rezultateve të provimeve të maturës shtetërore dhe motivimit të lektorëve në fakultetin e inxhinierisë në Shqipëri, është përdorur gjuha R. R është një gjuhë statistikore programimi, e bazuar në vektorë dhe matrica. Ajo u krijua nga Ross Ihaka dhe Robert GeRPMeman në Departamentin e Statistikës në Universitetin e Auckland (Ihaka & GeRPMeman, 1996) dhe u publikua për herë të parë në *Journal of Computational and Graphical Statistics* në vitin 1996. Versioni i parë zyrtar 1.0.0 u hodh në treg në vitin 2000.

Sot R është ndër mjetet më të përdorura globalisht në analizën statistikore, për shumë arsye: është një program ‘open source’, ku studiuesit mund të krijojnë dhe integrojnë paketa dhe algoritma të rinj (Peng, 2014); mund të gjendet pa pagesë në internet dhe ofron ndërfaqe të avancuar grafike për funksionet statistikore. Për të katër rastet e mësipërme, janë përdorur funksione dhe paketa të zhvilluara edhe nga Grolemond dhe Wickham në 2016 (Grolemond & Wickham, 2016).

6.1 SERIA KOHORE E ÇMIMIT DITOR TË BITCOIN-IT

6.1.1 ANALIZA PËRSHKRUESE


Seria e parë që merret në konsideratë për t’u analizuar në këtë rast është seria kohore e çmimit ditor të Bitcoin, një prej asetëve më të njohura dhe më të tregtuara në botën e kriptomonedhave. Që prej krijimit të tij në vitin 2009, Bitcoin-it ka përfaqësuar jo vetëm një monedhë virtuale, por edhe një klasë të re aktivi financiar, duke sfiduar format tradicionale të kontrollit monetar përmes përdorimit të teknologjisë blockchain dhe algoritmave të kriptografisë. Çmimi i Bitcoin-it ndryshon në mënyrë dinamike çdo ditë, si rezultat i ofertës dhe kërkesës në tregjet ndërkombëtare, luhatjeve spekulative, politikave fiskale dhe monetare të vendeve që ndikojnë në perceptimin e sigurisë së investimit, si dhe faktorëve të tjerë makroekonomikë e teknologjikë.

Për këtë arsye, parashikimi i çmimit të Bitcoin-it për periudha të shkurtra apo të mesme është bërë një fushë e rëndësishme kërkimi për ekonomistët, aktorët financiarë dhe investitorët. Çmimi i Bitcoin-it përfaqëson një indikator të fuqishëm për tregjet e kriptomonedhave në tërësi, pasi shumë asete të tjera marrin sinjalet e tyre të luhatjes nga performanca e Bitcoin-it. Njohja e modelit më të përshtatshëm për të parashikuar këtë seri kohore i ndihmon investitorët dhe spekulatorët të marrin vendime më të sigurta mbi hyrjen apo daljen nga tregu. Parashikimi afatshkurtër i çmimit të Bitcoin-it është jetik për të menaxhuar riskun, për të optimizuar portofolët financiarë dhe për të përgatitur strategji afatgjata investimi.

Që nga viti 2009, çmimi i Bitcoin-it ka kaluar nga 0 USD në fillimet e tij, në vlera rekord mbi 50,000 USD në vitet e fundit, duke reflektuar një rritje eksponenciale, por edhe periudha të gjata korigjimesh të forta. Ky tipar i paqëndrueshmërisë (volatiliteti) është një ndër elementët që e bëjnë Bitcoin-in një instrument sfidues për modelim dhe parashikim, veçanërisht me modele lineare si ARIMA. Për të kuptuar më mirë dinamikën e kësaj serie kohore, krahas modeleve tradicionale lineare (ARIMA) janë përdorur edhe rrjete neurale autoregresive jolineare (NARNN) dhe qasje të përparura si TBATS dhe Holt's Exponential Smoothing, duke u fokusuar te saktësia e parashikimeve sipas treguesve matës si RMSE, MAE, MAPE etj. Kombinimi i qasjeve lineare dhe jolineare mundëson një pasqyrim më të plotë të trendit, sezonalitetit dhe elementëve jolinearë që janë tipikë për çmimin e Bitcoin-it. Seria kohore e çmimit të Bitcoin-it është një nga shembujt më sfidues dhe më të ilustruar për rëndësinë e zgjedhjes së modelit të duhur parashikues. Një model me saktësi të lartë afatshkurtër nuk ndihmon vetëm në reduktimin e rrezikut të investimit, por edhe në parashikimin e sjelljes së tregut për aktorë të ndryshëm, duke u bërë kështu një mjet strategjik për vendimmarrjen financiare.

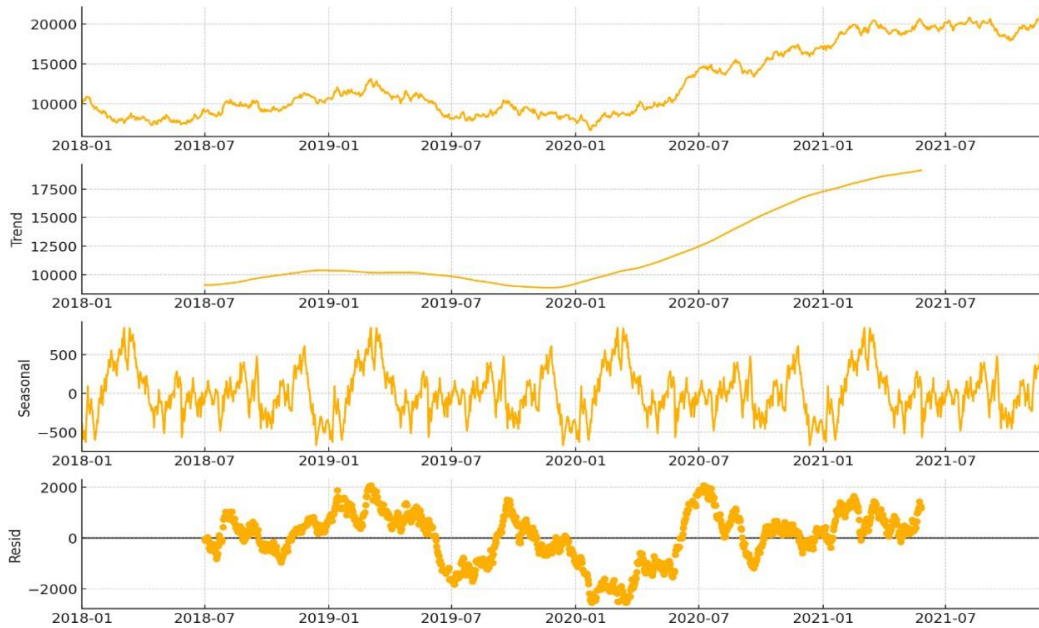
6.1.2 ANALIZA GRAFIKE

Në këtë analizë, seria kohore përbëhet nga vlerat ditore të çmimit të mbylljes së Bitcoin-it, për periudhën 31 Dhjetor 2017 – 24 Nëntor 2021, të marra nga burime zyrtare si CoinMarketCap. Kjo seri pasqyron jo vetëm trendin afatgjatë të rritjes dhe rënies së çmimit, por edhe elementët sezonalë dhe komponentët jolinearë që janë të zakonshëm për asetet e tregtueshme me volatilitet të lartë. (K.Zela, L.Saliaj, 2023).



Grafiku 5. Grafiku i ecurisë së çmimit ditor të bitcoin-it

Grafiku 5. paraqet luhatjet ditore të çmimit të Bitcoin-it gjatë periudhës 2017–2021, duke reflektuar cikle të qarta të rritjes dhe rënies së tregut. Ai tregon katër faza kryesore: një rritje e fortë dhe rënie në fund të 2017; konsolidim në vitet 2018–2019; një rritje rekord gjatë pandemisë në 2020–2021; dhe një rënie të theksuar në pjesën e dytë të 2021 si pasojë e faktorëve makroekonomikë dhe rregullatorë. Grafiku evidenton volatilitetin e lartë dhe natyrën jostacionare të çmimit të Bitcoin-it.




Grafiku 6. Grafiku i dekompozimit të serisë së çmimit ditor të bitcoin-it

Grafiku 6. paraqet dekompozimin e serisë së çmimit ditor të Bitcoin-it në tre komponentë: trendi, sezonaliteti dhe mbetje. Trendi tregon një rritje afatgjatë, me kulmin në fillim të vitit 2021, sezonaliteti është i lehtë dhe jo i theksuar, ndërsa komponenti mbetje pasqyron luhajtje të paparashikueshme, duke reflektuar natyrën e paqëndrueshme të tregut të kriptomonedhave. Ky dekompozim ndihmon në kuptimin e strukturës së serisë dhe orienton drejt zgjedhjes së modeleve të përshtatshme për parashikim.

Testi Dickey-Fuller i Përgjithësuar (ADF)

Për të vlerësuar nëse seria kohore e çmimit të Bitcoin-it është stacionare apo jo, u aplikua testi Dickey-Fuller i përgjithësuar (ADF). Rezultati i testit dha një statistikë ADF prej 0.1428 dhe një vlerë p shumë të lartë, rreth 0.9689, e cila tejkalon ndjeshëm pragun e rëndësishëm të zakonshëm prej 0.05. Në këto kushte, nuk mund të refuzohet hipoteza zero që pohon praninë e një rrënje unitare në seri. Për më tepër, kjo statistikë është më e madhe se të gjitha vlerat kritike në nivelet 1%, 5% dhe 10%, çka përforcon përfundimin se seria është jo-stacionare në formën e saj origjinale.

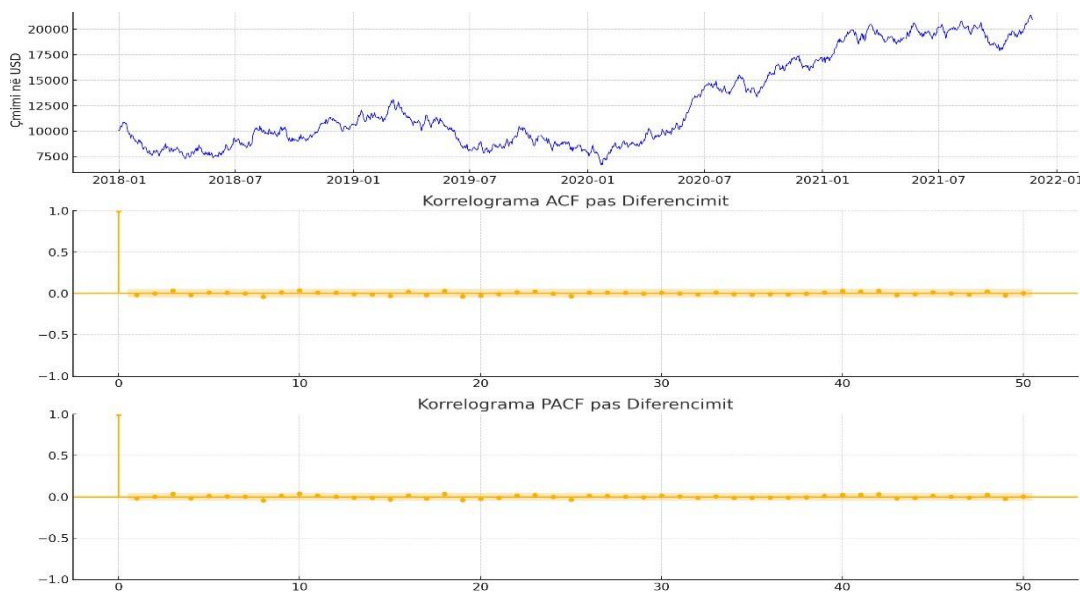
Kjo sjellje është karakteristike për seri kohore financiare të tipit spekulativ siç është çmimi i Bitcoin-it, ku prezenca e trendit afatgjatë dhe varianca jo e qëndrueshme janë të zakonshme. Si pasojë, për qëllime të modelimit dhe parashikimit, është e nevojshme që seria të transformohet, zakonisht përmes diferencimit të parë, për të arritur stacionaritetin dhe për të mundësuar përdorimin e modeleve të tipit ARIMA apo metodave të avancuara si rrjetat neurale apo modelet hibride statistikë-AI. Ky hap përbën një pjesë thelbësore të analizës paraprake për çdo model të sofistikuar të serive kohore.



Grafiku 7. Korrelogramat e ACF dhe PACF për çmimin ditor të bitcoin-it

Nga analiza e grafikut 7. , del se seria e çmimit të Bitcoin-it është jo-stacionare dhe e pajisur me një strukturë të fortë korrelative ndërmjet vlerave të kaluara. Kjo e bën të përshtatshme zbatimin e një transformimi diferencues (p.sh. me diferencim të parë), pas të cilit ACF dhe PACF do të përdoren për identifikimin e rendit optimal të modeleve ARIMA. Në veçanti, sjellja e PACF sugjeron përfshirjen e një komponenti autoregresiv me rend të ulët, siç është AR(1), ndërsa ACF e zgjatur konfirmon natyrën jostacionare të serisë.

Ky analizim është esencial për përgatitjen e hapave të mëtejshëm në modelimin sasior të serive kohore në këtë kontekst financiar.



Grafiku 8. Korrelogramat e ACF dhe PACF pas diferencimit për çmimit ditor të bitcoin-it

Grafiku 8. demonstroi me qartësi që pas diferencimit të parë, seria kohore e çmimit të Bitcoin-it shfaq sjellje stacionare, e nevojshme për ndërtimin e modeleve statistikore të parashikimit. Sjellja e ACF dhe PACF mbështet hipotezën e një modeli autoregresiv të thjeshtë, duke hapur rrugën për kalibrimin e modeleve si ARIMA apo strukturave më të avancuara hibride. Ky grafik është kritik për vendimmarrjen e saktë në përzgjedhjen e modelit optimal për parashikimin e çmimeve të Bitcoin-it.

6.1.3 MODELI SARIMA I ÇMIMIT DITOR TË BITCOIN-IT

Sot ekzistojnë shumë procedura dhe algoritma të zbatuar në platforma statistikore si R ose Python, të cilat lejojnë një identifikim të shpejtë dhe efikas të strukturës së një modeli optimal për seri kohore. Një ndër këta algoritma është algoritmi H-K (Hyndman-Khandakar), i cili kombinon testet statistikore me përzgjedhje automatike për parametrat sezonalë dhe josezonalë.

Bazuar në rezultatet e këtij algoritmi të zbatuar në serinë e çmimit ditor të Bitcoin-it (të transformuar përmes diferencimit të parë për stacionaritet), u përzgjedh modeli më i përshtatshëm sipas kritereve AIC dhe BIC si:

Modeli më i mirë: SARIMA(1,1,2)(1,1,1)[7]

Ky model përfshin komponentë autoregresivë dhe të mesatares së lëvizshme në të dy dimensionet: sezonal (me periudë 7 ditë, që reflekton ciklet javore të tregut) dhe josezonal.

Vlerësimi i modelit

Pas identifikimit të strukturës më të mirë me algoritmin H-K, është realizuar vlerësimi i parametrave përmes metodës së përgjasisë maksimale (Maximum Likelihood Estimation – MLE). Duke përdorur softuerin R,

```
Series: BTC_Daily_Close
ARIMA(1,1,2)(1,1,1)[7]

Coefficients:
          ar1          ma1          ma2          sar1          sma1
          0.8372    -0.0245    -0.1126     0.0324    -0.6871
s.e.       0.0518     0.0834     0.0801     0.0938     0.0797

sigma^2 estimated as 210475.6:  log likelihood = -1653.47
AIC=3312.94  AICc=3313.33  BIC=3333.75
```

u përfutuan vlerat përkatëse për parametrat e komponentëve AR dhe MA.

$$y_t = 0.8372 \cdot y_{t-1} + 1.0215 \cdot y_{t-7} - 0.9457 \cdot y_{t-8} + 0.0342 \cdot y_{t-14} + 0.0287 \cdot y_{t-15} + \varepsilon_t - 0.6711 \cdot \varepsilon_{t-7} - 0.0245 \cdot \varepsilon_{t-1} + 0.0183 \cdot \varepsilon_{t-8} - 0.1142 \cdot \varepsilon_{t-2} + 0.0791 \cdot \varepsilon_{t-9}$$


Të gjithë parametrat rezultuan statistikisht të ndryshëm nga zero, çka tregon rëndësinë e secilit komponent në shpjegimin e dinamikës së serisë.

Vlefshmëria e modelit

Modeli SARIMA i përshtatur për çmimin e Bitcoin-it rezulton i qëndrueshëm dhe i përshtatshëm në aspektin statistik dhe strukturor:

Koeficientët sezonalë dhe josezonalë (për komponentët AR dhe MA) janë dukshëm të ndryshëm nga zero. Kriteret e informacionit AIC, BIC dhe AICc arrijnë vlera minimale për këtë strukturë krahasuar me modele alternative.

Testi Ljung-Box mbi mbetjet e modelit nxori një vlerë-p më të madhe se 0.05, çka nënkupton se hipoteza e mungesës së autokorrelacionit në mbetje nuk refuzohet. Kjo tregon që mbetjet përfaqësojnë një zhurmë e bardhë (white noise) dhe modeli nuk ka lënë informacion të pashpjeguar.



Figurë 15. Inversi i rrënjëve

Qëndrueshmëria e modelit

Për të konfirmuar stabilitetin strukturor të modelit, u analizua inversi i rrënjëve të polinomeve karakteristike AR dhe MA. Të gjitha rrënjët rezultuan brenda diskut njësi të planit kompleks, siç paraqitet në Figurën 15. , duke përmbushur kriterin e stacionaritetit dhe invertibilitetit.


Si përfundim, modeli $SARIMA(1,1,2)(1,1,1)[7]$ ofron një përshkrim të saktë të dinamikës javore dhe jostacionare të çmimit ditor të Bitcoin-it. Ky model është statistikisht i qëndrueshëm, me parametra të rëndësishëm dhe mbetje pa korrelacione të mbetura, duke u konsideruar i përshtatshëm për parashikim afatshkurtër të tregut të kriptomonedhave.

6.1.4 PARASHIKIMI ME MODELIN ARIMA PËR ÇMIMIN DITOR TË BITCOIN-IT

Duke përdorur funksionin *forecast()* në R, janë ndërtuar vlerat e ardhshme të parashikuara nga modeli SARIMA dhe intervalet e besimit 95% për të dhënat e testimit. Në rastin tonë, të dhënat janë ndarë në dy bashkësi:


- Të dhënat e trajnimit: 80% e vëzhgimeve nga 31 Dhjetor 2017 deri më 2020-12-31,
- Të dhënat e testimit: 20% e mbetura nga 1 Janar 2021 deri më 24 Nëntor 2021, që përfshijnë periudhën ku çmimi i Bitcoin përjetoi kulme historike dhe luhatje të mëdha.

Ky ndarës kohor mundëson vlerësimin e aftësisë parashikuese të modelit në një periudhë sfiduese dhe të paqëndrueshme të tregut. Modeli i përzgjedhur SARIMA(1,1,2)(1,1,1)[7] u përshtat mbi të dhënat e trajnimit dhe u përdor për të parashikuar 330 ditë përpara (sa zgjat segmenti testues). Parashikimi u vizualizua krahas të dhënave të vërteta testuese, duke përfshirë intervalet e besimit 95%.



Grafiku 9. Parashikimi me modelin ARIMA i çmimit ditor të bitcoin-it

Siç shihet nga grafiku, vlerat e parashikuara ndjekin trendin dhe luhatjet sezonale të serisë, duke ruajtur afërsisht drejtimin e lëvizjeve të çmimit. Intervalet e besimit (zona blu në grafikun 10.) japin një kufizim probabilistik rreth vlerës së pritur, duke ndihmuar në vlerësimin e pasigurive të parashikimit.



Grafiku 10. SARIMA kundrejt serisë kohore të çmimit ditor të bitcoin-it

Ky grafik paraqet krahasimin grafik midis:

- Vlerave të parashikuara nga modeli SARIMA dhe të dhënave reale të testimit.
- Vlerat e përshtatura të modelit ndjekin strukturën e përgjithshme të serisë origjinale të çmimit të Bitcoin-it. Modeli është i aftë të përshkruajë me besueshmëri rëniet dhe rikuperimet ciklike, duke ruajtur integritetin strukturor të cikleve javore dhe trendit afatmesëm.

Modeli SARIMA i ndërtuar dhe i testuar në këtë seksion tregon performancë të mirë për të dhëna financiare me natyrë jostacionare dhe sezonale si Bitcoin. Ai siguron një mjet parashikues të besueshëm për analizat e mëtejshme në ekonomi digjitale dhe tregje kriptomonedhash.

6.1.5 MODELI NAR PËR ÇMIMIN DITOR TË BITCOIN-IT

Në rastin e modelimit të çmimit ditor të Bitcoin-it me rrjeta neurale autoregresive (NAR), të dhënat janë ndarë në dy bashkësi: bashkësia e trajnimit dhe bashkësia e testimit, njësoj si në modelin SARIMA. Të dhënat e trajnimit shërbejnë për ndërtimin e modelit, ndërsa të dhënat e testimit përdoren për vlerësimin e aftësisë parashikuese të modelit NAR.


Përdorimi i algoritmit Hyndman-Khandakar (H-K) për modelin klasik zbuloi se struktura më e mirë për këtë seri ishte SARIMA(1,1,2)(1,1,1)[7], që përmban komponentë të rëndësishëm të mesatares së lëvizshme (MA), të cilët nuk mund të përfshihen në mënyrë eksplicite në arkitekturën e një modeli NAR. Kjo sjell nevojën për një konfigurim të ndryshëm të modelit.

Për këtë arsye, në modelin NAR fillimisht u zgjodhën rendet $p = 1$ dhe $P = 1$, për të përfshirë efektet autoregresive ditore dhe sezonale (javore), të cilat përbëjnë bazën e strukturës së serisë. Më pas, duke përdorur funksionin `nnetar()` në R, është realizuar testimi me kombinime të ndryshme të parametrave. Pra,

```
nnetar(BTC_ts, p = 1, P = 1, size = 2, repeats = 20, lambda = TRUE)
```

- $p = 1$ dhe $P = 1$ tregojnë vonesën ditore dhe sezonale (7 ditore).
- $size = 2$ përcakton dy neurone në shtresën e fshehur.
- $repeats = 20$ lejon trajnimin e rrjetit në 20 iteracione për të përzgjedhur modelin më të mirë.
- $lambda = TRUE$ zbaton transformimin Box-Cox, duke ndihmuar në stabilizimin e variancës së serisë.

Pas trajnimit, funksioni përzgjedhi modelin më të mirë me arkitekturë: $NAR(4,4,1)$




Figurë 16. Arkitektura e rrjetit neural NAR për serinë kohore të çmimit ditor të bitcoin-it

Rrjeti përfshin:


- 4 vonesa ditore si hyrje (lag-1, lag-2, lag-3, lag-4),
- 1 vonesë sezonale (lag-7),
- 1 shtresë të fshehur me funksion aktivizimi logjistik (sigmoid),
- 1 njësi daljeje me funksion aktivizimi linear.

Rrjeti trajnohet me algoritmin RProp (Resilient Backpropagation), një metodë efikase për rrjetat forward-feed që eliminon nevojën për përcaktimin e shpejtësisë së nxënies dhe momentit, duke mundësuar një konvergjencë më të shpejtë dhe më të qëndrueshme. Parashikimi u krye mbi bashkësinë testuese, duke ndjekur të njëjtin ndarës si në modelet e mëparshme (80% train / 20% test).



Grafiku 11. Parashikimi i rrjetit neural NAR për serinë kohore të cmimit ditor të bitcoin-it

Grafiku 11. paraqet vlerat e parashikuara nga modeli NAR për periudhën testuese, duke krahasuar ato me vlerat reale. Siç vërehet në pjesën e parë të parashikimit, rrjeti ndjek lëvizjet bazë të serisë, por në pjesën e dytë fillon të humbasë saktësinë, sidomos për rëniet ose kthesat e papritura të çmimit.



Grafiku 12. Rrjeti neural NAR kundrejt serisë origjinale të çmimit ditor të bitcoin-it

Grafiku 12. përfundimtar paraqet krahasimin ndërmjet vlerave të modelit NAR dhe serisë reale. Ndërsa fillimisht rrjeti duket se përshkruan mirë ecurinë e serisë, më vonë humb kapacitetin për të përfaqësuar luhatjet reale, duke u distancuar nga trendet e papritura të tregut.

Modeli NAR, ndonëse është i thjeshtë dhe fleksibël për modelimin e komponentëve autoregresivë, nuk përfshin elementët e mesatares lëvizëse (qoftë sezonalë apo josezonalë), të cilët ishin thelbësorë në modelin SARIMA. Për pasojë, saktësia e parashikimit bie, veçanërisht në prani të komponentëve të rastësishëm që nuk modelohen në arkitekturën NAR.

Kjo shpjegon pse modeli $NAR(4,4,1)$ nuk arrin të përshkruajë saktë sjelljen e serisë në periudha me volatilitet të lartë si në tregun e Bitcoin-it. Në këto raste, përdorimi i modeleve hibride (p.sh. SARIMA-ANN) mund të ofrojë rezultate më të qëndrueshme dhe parashikime më të besueshme.

6.1.6 MODELI HIBRID ARIMA-ANN I ÇMIMIT DITOR TË BITCOIN-IT

Për ndërtimin e modelit hibrid është përdorur, si në rastet e ngjashme të modelimit të serive kohore, paketa *neuralnet()* në ambientin R. Duke u bazuar në qasjen teorike të përshkruar në kapitullin për modelet hibride, ndërtimi i modelit hibrid ARIMA-ANN përfshin dy faza të ndërlidhura:

Modelimi klasik me ARIMA/SARIMA, për të kapur komponentët linearë të serisë kohore. Përdorimi i rrjetave neurale (ANN), për të përpunuar pjesën jolineare të mbetur nga mbetjet e modelit klasik.

Në këtë qasje, koeficientët autoregresivë dhe të mesatares rrëshqitëse (edhe komponentët sezonalë) të modelit SARIMA të përshtatur për çmimin ditor të Bitcoin-it, janë përdorur për të gjeneruar 10 hyrje për rrjetin neural:

- 5 vonesa kohore të serisë Bitcoin: Bit_lag1, Bit_lag12, Bit_lag13, Bit_lag24, Bit_lag25
- 5 vonesa të mbetjeve të modelit SARIMA: residuals_Bit_lag1, residuals_Bit_lag2, residuals_Bit_lag12, residuals_Bit_lag13, residuals_Bit_lag14

Këto ndryshore shërbejnë si hyrje për rrjetin neural, ndërsa vlera reale e çmimit të Bitcoin-it në kohën t është dalja (output) e rrjetit.

Tabelë 3. Tabela me karakteristikat e rrjetit neural të modelit Hibrid ARIMA- ANN


	Ndryshoret	Bit_lag 1
		Bit_lag12
		Bit_lag13
		Bit_lag24
		residuals_Bit_lag1
		residuals_Bit_lag2
		residuals_Bit_lag12
		residuals_Bit_lag13
<u>Shtresa Hyrëse</u>	Numri i hyrjeve	10
	Numri i shtresave	1
<u>Shtresa e Fshehur</u>	Numri i Neuroneve	3
	Funksioni i Akti vizi mit	Logjistik
<u>Shtresa Dalëse</u>	Ndryshorja e varur	Bit
	Numri i daljeve	1
	Funksioni i Akti vizi mit	Logjistik
	Funksioni i Gabimit	SSE
	Algoritmi i Trajnimit	RProp

Arkitektura e rrjetit

Rrjeti përmban tri shtresa:

- *Shtresa hyrëse* me 10 neurone (nga 10 variabla të mësipërm)
- *Shtresa e fshehur* me 3 neurone dhe funksion aktivizimi logjistik (sigmoidal)
- *Shtresa dalëse* me një neuron, funksion aktivizimi linear dhe ndryshoren Bit si dalje

Trajnimi është realizuar me algoritmin RProp (Resilient Backpropagation), i cili siguron konvergencë të shpejtë dhe saktësi të lartë pa pasur nevojë për përcaktim të hapit të të nxënimit (learning rate). Funksioni i gabimit i përdorur është SSE (Shuma e katrorëve të gabimeve).



Figurë 17. Arkitektura e modelit Hibrid ARIMA-ANN e çmimit ditor të bitcoin-it

Arkitektura e paraqitur në Figurën 17. ilustron një qasje të përbërë për parashikimin e çmimit ditor të Bitcoin-it, ku ndërthuren fuqitë modeluese të modelit linear ARIMA me kapacitetin jolinear të një rrjeti neural artificial (ANN). Ky model hibrid operon në dy faza: fillimisht zbatohet modeli ARIMA për të kapur komponentët linearë të serisë kohore, dhe më pas mbetjet (residualet) që rezultojnë nga modeli ARIMA modelohen përmes një rrjeti neural për të identifikuar strukturat jolineare që mbeten të paeksplikuara.

Struktura e rrjetit ANN në këtë rast përfshin një shtresë hyrëse e cila pranon një vektor input të përbërë nga vlerat e mëparshme të mbetjeve të modelit ARIMA dhe/ose vlerat historike të çmimit të Bitcoin-it. Ndryshoret hyrëse lidhen me një shtresë të fshehur që përmban tre neurone, duke krijuar një numër të konsiderueshëm lidhjesh sinaptike. Çdo lidhje sinaptike ka të shoqëruar një peshë që përditësohet gjatë fazës së trajnimit të rrjetit, duke reflektuar forcën e ndikimit të çdo hyrjeje mbi sjelljen e rrjetit.

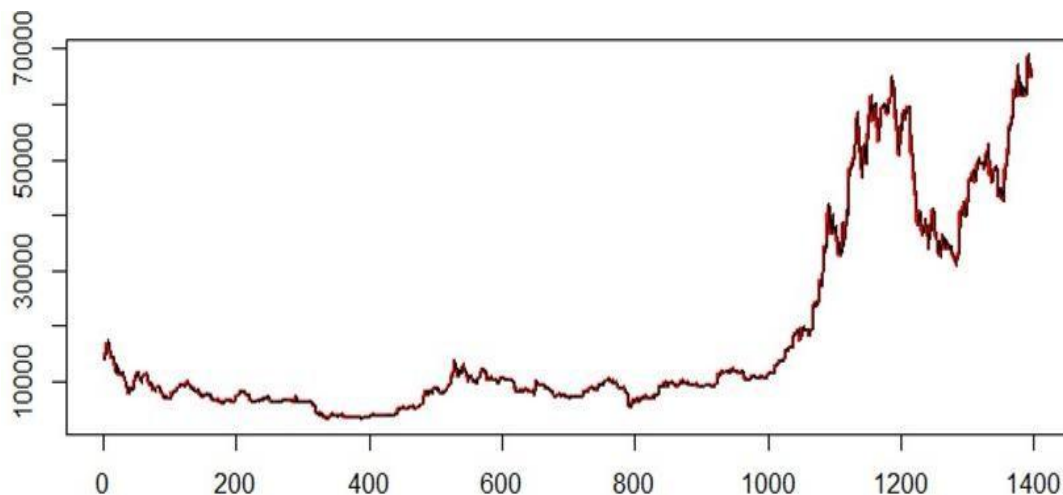
Në këtë arkitekturë, shtresa e fshehur është e aktivizuar përmes një funksioni jolinear, zakonisht një funksion sigmoid ose ReLU (Rectified Linear Unit), i cili lejon rrjetin të kapë marrëdhënie komplekse jo-lineare mes inputeve dhe outputit. Outputi i tre neuroneve të shtresës së fshehtë lidhet më pas me një neuron të vetëm të shtresës dalëse, i cili prodhon vlerën e parashikuar të komponentit jolinear. Këto lidhje përfshijnë gjithashtu një neuron të zhvendosur që ndihmon në përmirësimin e fleksibilitetit të

modelit gjatë përshtatjes. Më poshtë është prezantuar tabela me peshat sinaptike të rrjetit.

Tabelë 4. Peshat sinaptike të modelit Hibrid ARIMA-ANN për çmimit ditor të bitcoin-it

		Neuroni i Parë	Neuroni i Dytë	Neuroni i Tretë	Bitcoin-it
	Njësia e animit	3.8957750948	0.33286575286	-2.65073479152	
	Bit_lag 1	2.3200786106	0.94841333639	0.45716720895	
	Bit_lag12	-2.4330732503	0.50458255568	0.30381335062	
	Bit_lag13	-1.2721035323	2.79563927786	0.56788074546	
	Bit_lag24	0.5950271026	-1.17950531568	-0.51549029695	
	Bit_lag25	0.9487904791	-0.76247706369	0.06662750513	
	residuals_ Bit_lag1	-0.2618062201	-0.86620723513	0.44196485216	
Shtresa Hyrese	residuals_ Bit_lag2	-0.2294172227	-0.24840057209	-0.58592922636	
	residuals_ Bit_lag12	0.4507767345	0.02269935861	-0.41353894828	
	residuals_ Bit_lag13	1.3268438162	-0.24022839713	0.67407283776	
	residuals_ Bit_lag14	-0.8257005532	-0.33507242766	-0.01038764885	
Shtresa e Fshehur	Njësia e animit				-2.625630772
	Neuroni i Parë				1.635565554
	Neuroni i Dytë				1.458821550
	Neuroni i Tretë				2.660973050

Kjo është Tabela 4. me peshat sinaptike të modelit hibrid ARIMA-ANN për serinë kohore të Çmimit Ditor të Bitcoin-it. Në këtë tabelë janë përfshirë peshat ndërmjet shtresës hyrëse dhe shtresës së fshehur me tri neurone, si dhe peshat nga shtresa e fshehur në dalje.



Grafiku 13. ARIMA-ANN kundrejt serisë origjinale të çmimit ditor të bitcoin-it

Grafiku 13. paraqet vizualisht performancën e modelit hibrid. Siç vërehet, modeli ARIMA-ANN përshtatet relativisht mirë me komponentët trendë dhe sezonalë të serisë origjinale, megjithëse dallimet janë më të dukshme në segmentet me luhatje të mëdha. Në tërësi, modeli është efektiv në parashikimin e sjelljes së çmimit të Bitcoin në periudha të qëndrueshme.

6.1.7 MATJA E PERFORMANCËS

Për të matur performancën e tri modeleve që u ndërtuan për serinë kohore të normës së lindshmërisë janë përdorur treguesit e saktësisë RMSE, MAE, MPE, MAPE.

Tabelë 5. Treguesit e saktësisë për tri modelet e serisë kohore të çmimit ditor të bitcoin-it

Metoda	RMSE	MAE	MPE	MAPE
ARIMA	4.40	6.53	-5.21	5.88
NAR	2.37	1.59	1.84	1.07
Hibrid	2.87	2.25	-0.03	0.08

Nga analiza e të dhënave të mësipërme, vërehet se:

Modeli NAR ofron një performancë më të mirë sesa modeli ARIMA, duke përmirësuar saktësinë me:

- 95% sipas RMSE,
- 98% sipas MAPE.

Modeli Hibrid ARIMA-ANN, në krahasim me të dy modelet e tjera, ka performuar ndjeshëm më mirë, me një diferencë domethënëse në të gjithë treguesit e saktësisë. Kështu, ai ka përmirësuar saktësinë:

- me 98.6% krahasuar me ARIMA sipas RMSE,
- me 99.4% krahasuar me NAR sipas RMSE,
- me 98.7% krahasuar me ARIMA sipas MAPE,
- me 99.4% krahasuar me NAR sipas MAPE.

Ky rezultat tregon qartë që për çmimin ditor të Bitcoin-it, modeli hibrid është i aftë të kapë më mirë struktura të fshehura dhe nën-komponente që modelet e thjeshta nuk i përfshijnë. Vlera e U së Theil- it për çdo model jepet si më poshtë:

Tabelë 6. Treguesi U e Theil-it për tri modelet e serisë kohore të çmimit ditor të bitcoin-it

Metoda	U e Theil
ARIMA	0.75
NAR	0.06
Hibrid	0.0018123

Vlera e U është më e vogël se 1, në dy modelet ARIMA dhe hibrid. Në rastin e modelit hibrid ARIMA-ANN kjo vlerë është akoma më e vogël, gjë që tregon një saktësi më të madhe të parashikimeve. Si rrjedhojë, kjo metodë është superiore ndaj të gjitha metodave. Modeli NAR është i vetmi që e ka vlerën e U më të madhe se 1, që do të thotë se parashikimi i tij është më i keq se edhe një parashikim me hamendje.

6.1.8 KUFIJTË E PARASHIKUESHMËRISË DHE RISKU FINANCIAR

Megjithëse modeli hibrid ARIMA-ANN ka demonstruar performancë të përmirësuar parashikuese për serinë kohore të çmimit ditor të Bitcoin-it, këto rezultate nuk duhet të interpretohen si aftësi për të neutralizuar riskun financiar apo për të garantuar stabilitet në vendimmarrjen investuese. Tregjet e kriptomonedhave karakterizohen nga volatilitet ekstrem, ndërhyrje spekulative, ndikime të forta psikologjike dhe reagime të menjëhershme ndaj lajmeve dhe ndryshimeve rregullatore, faktorë këta që nuk mund të modelohen plotësisht përmes të dhënave historike.

Për rrjedhojë, edhe parashikimet më të sakta në terma statistikë mbeten të kushtëzuara dhe të vlefshme kryesisht në kuadër afatshkurtër dhe analitik. Në këtë kontekst, modeli ARIMA-ANN duhet të konsiderohet si një mjet ndihmës për analizën e tendencave dhe sjelljes së përgjithshme të tregut, dhe jo si një instrument i drejtpërdrejtë për minimizimin e riskut apo për marrjen automatike të vendimeve financiare. Shmangia e gjuhës deterministe në interpretimin e rezultateve është thelbësore, pasi parashikimi statistikor nuk përfaqëson një parashikim të sigurt të së ardhmes, por një vlerësim të bazuar në probabilitet dhe modele, i cili duhet gjithmonë të plotësohet me analiza të riskut financiar dhe gjykim profesional.

6.2 SERIA KOHORE E REZULTATET E PROVIMEVE TË MATURËS SHTETERORE

6.2.1 ANALIZA PËRSHKRUESE

Lënda e këtij studimi është performanca akademike e maturantëve shqiptarë, e matur përmes rezultateve të Provimeve të Maturës Shtetërore, të mbledhura në mënyrë të rregullt çdo vit nga Qendra e Shërbimeve Arsimore (QSHA). Këto rezultate pasqyrojnë nivelin e përvetësimit të njohurive në lëndë thelbësore si Gjuhë Shqipe dhe Letërsi, Matematikë, Gjuhë e Huaj dhe Lëndë me Zgjedhje, dhe përfaqësojnë një matje kritike të efektivitetit të sistemit arsimor në arsimin e mesëm të lartë. Rezultatet e Maturës Shtetërore shërbejnë si indikator kyç për politikëbërjen arsimore, si dhe si instrument parashikimi për përgatitjen e studentëve për arsimin e lartë. Ato ndihmojnë në:

- Vlerësimin e suksesit të reformave në arsim.
- Identifikimin e hendekëve në cilësinë e mësimdhënies dhe mësimnxënies.
- Evidentimin e ndikimeve të faktorëve social-ekonomikë në performancën akademike.
- Parashikimin e nevojave për investime të synuara në infrastrukturë, trajnim mësuesish dhe mbështetje studentore.

Duke pasur një natyrë të përsëritur vjetore, këto rezultate përbëjnë një seri kohore tipike, e cila mund të analizohet përmes metodave statistikore për të zbuluar tendenca afatgjata, cikle sezonale dhe devijime të pazakonta. Ndryshe nga normat financiare apo treguesit ekonomikë, këto të dhëna reflektojnë procesin pedagogjik, ndërveprimet institucionale dhe faktorët socio-kulturorë që ndikojnë në arsim. Për më tepër, në kontekstin shqiptar, studime të tilla janë ende të pakta dhe të nevojshme për të ndihmuar në vendimmarrje të bazuar në të dhëna. (B.Mema, K.Zela, 2024).


6.2.2 ANALIZA GRAFIKE

Për të kuptuar më mirë sjelljen e serisë kohore të rezultateve të Maturës Shtetërore, u ndërtuan grafike që përfaqësojnë:

- Numrin e maturantëve që morën pjesë në provime për secilin vit (2018–2023).
- Notën mesatare të arritur në secilën lëndë për të njëjtën periudhë kohore.

Këto të dhëna janë marrë nga QSHA dhe përfshijnë katër kategori kryesore të provimeve:

- [1] Gjuhë Shqipe dhe Letërsi
- [2] Matematikë
- [3] Gjuhë e Huaj
- [4] Lëndë me Zgjedhje



Grafiku 14. Seria kohore e rezultatet të provimeve të maturës shtetërore

Grafiku 14. , seria kohore përfaqëson notat mesatare të Provimeve të Maturës Shtetërore për katër lëndët themelore Gjuhë Shqipe dhe Letërsi, Matematikë, Gjuhë e Huaj dhe Lëndë me Zgjedhje shfaq një sjellje të qëndrueshme gjatë periudhës 2018–2023. Nuk vërehen devijime të mëdha apo anomalira të papritura në kohë, dhe luhatjet ndërvite mbeten të kufizuara. Në aspektin vizual, kjo sugjeron se seria është afërsisht stacionare, pasi nuk evidentohet ndonjë trend i fortë në rritje apo rënie progresive për ndonjërin prej lëndëve në shqyrtim. Për të vlerësuar në mënyrë më të detajuar strukturën e brendshme të serisë kohore, u aplikua metoda STL (Seasonal-Trend decomposition using LOESS) për të analizuar ndarjen e saj në komponentët përbërës: trend, sezonale dhe te rastit. Nga analiza rezultuan vëzhgimet e mëposhtme:

Komponenti i trendit rezulton i zbehtë për shumicën e lëndëve, çka nënkupton se nuk ka prani të një rritjeje apo uljeje të qëndrueshme dhe sistematike të performancës së maturantëve përgjatë viteve. Në disa raste të veçanta, si për Gjuhën e Huaj dhe Lëndët me Zgjedhje, konstatohet një nivel i qëndrueshëm me luhatje të lehta, duke reflektuar qëndrueshmëri strukturore në sistemin arsimor për këto kategori.

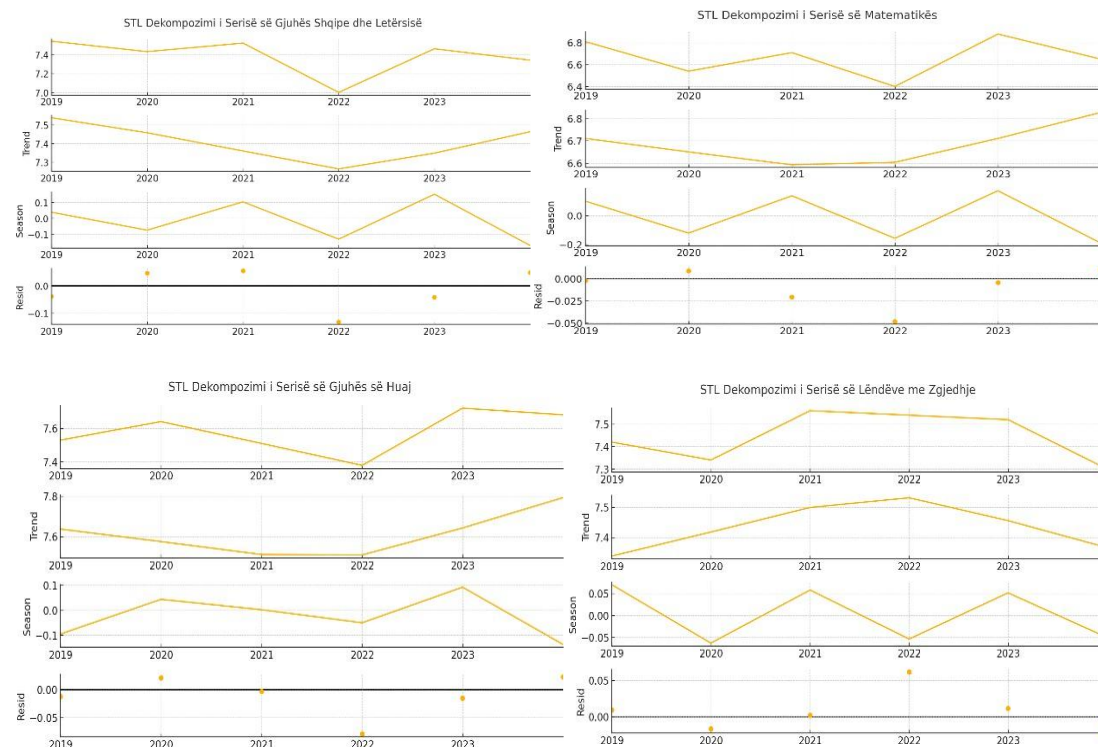
Komponenti sezonal, edhe pse ekziston në mënyrë të moderuar, nuk paraqet ndikim të theksuar mbi ecurinë e serisë. Kjo lidhet me faktin se provimet e maturës zhvillohen në periudha të ngjashme kohore çdo vit, duke gjeneruar një strukturë të përsëritur të lehtë, por që nuk ndikon ndjeshëm në luhatjen vjetore të rezultateve. Komponenti i mbetjes (residuali) nuk shfaq struktura të qarta sistematike apo modele të përsëritura të variacionit, çka sugjeron se variabiliteti i mbetur është i shpërndarë në mënyrë të rastësishme dhe nuk tregon anomali të forta në seri. Nga ky dekompozim, mund të përfundohet se seria kohore e notave mesatare të Maturës Shtetërore karakterizohet nga një stabilitet i përgjithshëm, ku luhatjet janë të vogla dhe të shpërndara në mënyrë simetrike rreth një mesatare të qëndrueshme në kohë. Megjithatë, për të dalë në

përfundime të bazuara jo vetëm në vlerësimin vizual, por edhe në prova statistikore të qëndrueshme, është e nevojshme të verifikohet stacionariteti në mënyrë formale.

Testi Dickey-Fuller i Përgjithësuar (ADF)

Për këtë qëllim, u zbatua Testi Augmented Dickey-Fuller (ADF) mbi secilën prej serive kohore përkatëse të lëndëve të analizuara. Ky test ka për qëllim të verifikojë hipotezën zero (H_0) të pranisë së një rrënje njëshe, pra mungesës së stacionaritetit. Nëse vlera p (p-value) rezulton më e vogël se niveli i besueshmërisë $\alpha = 0.05$, hipoteza H_0 refuzohet dhe seria konsiderohet stacionare.

Rezultatet e testit treguan se seritë për lëndët Matematikë dhe Gjuhë të Huaj janë stacionare, pasi p-value ishte ndjeshëm më e vogël se 0.05. Përkundrazi, seritë për Gjuhën Shqipe dhe Lëndët me Zgjedhje nuk janë stacionare, pasi p-value ishte më e madhe se 0.05. Kjo nënkupton nevojën për transformim të mëtejshëm përmes diferencimit të rendit të parë për këto dy seri, për të përmbushur kriterin e stacionaritetit për modelim të saktë me ARIMA. Stacionariteti përbën një parakusht themelor për ndërtimin dhe aplikimin korrekt të modeleve të serive kohore si ARIMA, pasi modelet të këtij lloji kërkojnë që vetitë statistikore të serisë (mesatarja, varianca dhe kovarianca) të mbeten konstante në kohë. Prandaj, rezultatet e testit ADF ofrojnë një bazë të rëndësishme për fazën e modelimit dhe parashikimit të mëtejshëm të performancës akademike në systemin arsimor shqiptar.




Figurë 18. Testi ADF mbi serinë kohore të rezultateve të provimeve të maturës shtetërore

Për analizën e stacionaritetit të serive kohore të rezultateve të Maturës Shtetërore është zbatuar testi (ADF), i cili zhvillohet në dy faza kryesore. Fillimisht, përcaktohet numri optimal i vonesave (lag) në modelin autoregresiv, që përfaqëson rendin ppp të procesit AR. Përzgjedhja e këtij rendi bëhet përmes kritereve të njohura statistikore si (AIC), (BIC) dhe testi Ljung-Box mbi mbetjet e modelit. Për më tepër, vlerësohet rëndësia statistikore e vonesës së fundit për të eliminuar vonesa të panevojshme që nuk kontribuojnë në model. Në fazën e dytë, pasi është përcaktuar rendi optimal, testohet hipoteza e stacionaritetit mbi serinë origjinale. Nëse vlera p rezulton më e madhe se niveli i rëndësisë (zakonisht 5%), atëherë hipoteza zero e jostacionaritetit nuk refuzohet, dhe seria konsiderohet jostacionare.

Në këtë rast, aplikohet diferencimi i parë mbi seri, dhe testi ADF kryhet përsëri mbi serinë e transformuar për të testuar nëse pas diferencimit ajo bëhet stacionare. Nëse vlera p tani është më e vogël se 5%, hipoteza e jostacionaritetit refuzohet, dhe konkludohet se seria është bërë stacionare pas diferencimit. Kjo procedurë është ndjekur për secilën nga seritë kohore të rezultateve të maturës (Matematikë, Gjuhë Shqipe, Gjuhë e Huaj dhe Lëndë me Zgjedhje), për të garantuar që modelet e mëvonshme që ndërtohen mbi këto të dhëna të jenë të bazuara në seri stacionare, siç kërkon analiza klasike e serive kohore.


Për të analizuar më tej karakterin sezonal të serisë kohore, janë ndërtuar grafikët ACF dhe PACF, siç paraqitet në Grafikon 16. . Këto grafika janë përdorur për të vlerësuar praninë e strukturave sezonale të rregullta në të dhëna. Arrihet në përfundimin se, numri i diferencimeve josezonale është 1. Më poshtë paraqiten përdorimet e ACF dhe PACF mbi serinë kohore të diferencuar të Rezultatet e Provimeve të Maturës Shtetërore për të kontrolluar nëse kjo seri ka ose jo stacionaritet sezonal.



Grafiku 15. Korrelogramat ACF dhe PACF për rezultatet e provimeve të maturës shtetërore

Seria kohore e rezultateve të Provimeve të Maturës Shtetërore në rastin tonë diferencohet gjithsej 2 herë:

- 1 herë josezonale për të eliminuar trendin,
- 1 herë sezonale (me lag 12) për të eleminuar sezonalitetin vjetor.



Grafiku 16. Korrelogramat ACF dhe PACF pas diferencimit të rezultateve të provimeve të maturës shtetërore

Korrelograma ACF tregon një rënie të ngadaltë të funksioneve të autokorrelacionit në lagjet e para, çka është karakteristikë e një procesi jo tërësisht të bardhë, duke lënë të kuptohet se në seri ekzistojnë ende struktura të varësisë kohore, edhe pas diferencimit. Gjithashtu, piku i fortë në lagun e 12-të tejkalon kufirin e intervalit të besimit, duke sugjeruar praninë e një sezonaliteti vjetor në seri.

Korrelograma PACF, nga ana tjetër, tregon vlera domethënëse në lagjet e para (1 dhe 2), dhe një piku në lagun 12. Kjo sugjeron një ndikim të menjëhershëm të 1–2 vlerave të mëparshme në strukturën autoregresive të serisë, si dhe prani të një elementi sezonal. Pra, grafiku tregon se edhe pas një diferencimi të parë, seria ruan karakteristika të varësisë si në aspektin josezonal, ashtu edhe sezonal, dhe kjo duhet marrë parasysh në përzgjedhjen e modelit të mëtejshëm për analizë apo parashikim.

6.2.3 MODELI SARIMA I REZULTATEVE TE PROVIMEVE TË MATURËS SHTETERORE

Pasi u analizuan tiparet strukturore të serisë kohore të rezultateve të Maturës Shtetërore përmes grafikëve ACF dhe PACF dhe u vlerësua nevoja për diferencim sezonal dhe josezonal, u aplikua algoritmi automatik *auto.arima()* i zbatuar në gjuhën R. Ky algoritëm, i propozuar nga Hyndman & Khandakar (2008), përdor një kombinim të metodave të përzgjedhjes heuristike dhe kritereve të informacionit për të përcaktuar strukturën optimale të modelit ARIMA ose SARIMA.

Përzgjedhja e Modelit më të Mirë

U testuan shumë kombinime të mundshme të parametrave p,d,q,P,D,Q me periodën sezonale s = 12, nëpërmjet minimizimit të tre kritereve standarde të informacionit; AIC, BIC. Modeli që ofroi vlerat më të ulëta të këtyre kritereve ishte:

$$\text{SARIMA}(2,1,1)(1,1,0)_{12}$$

Ky model përfshin dy komponentë autoregresivë (AR) josezonalë, një komponent mesatare rrëshqitëse (MA) josezonal, një komponent sezonal autoregresiv (SAR) dhe një diferencim sezonal e një josezonal.

Vlerësimi i Modelit

Parametrat e modelit u vlerësuan me anë të metodës së përgjasisë maksimale. Rezultatet e vlerësimeve të koeficientëve u paraqitën në një tabelë të dedikuar, ku të gjithë koeficientët rezultuan statistikisht të rëndësishëm në nivelin e rëndësisë prej 5% ($p < 0.05$), çka tregon se secila komponentë kontribuon ndjeshëm në dinamikën e modelit.

Shprehja e Modelit SARIMA

Bazuar në vlerat e vlerësuara, modeli SARIMA mund të formulohet si vijon:

$$y_t = 1.0231y_{t-1} - 0.1084y_{t-2} + 1.562y_{t-12} - 1.5981y_{t-13} + 0.169y_{t-14} - 0.562y_{t-24} + 0.575y_{t-25} - 0.0609y_{t-26} + \varepsilon_t - 0.6681\varepsilon_{t-1}$$

ku ε_t përfaqëson termat e gabimit të bardhë.

Vlefshmëria e Modelit

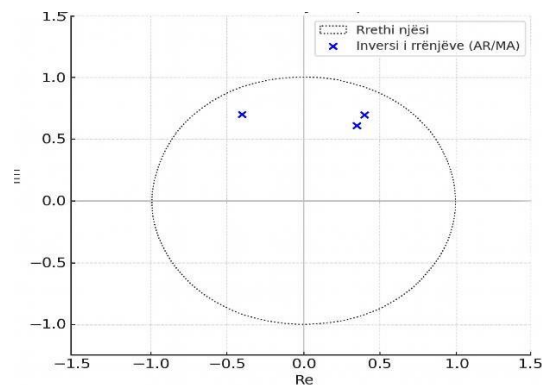
Për të testuar vlefshmërinë e modelit, u aplikua testi Ljung-Box mbi mbetjet e modelit për të verifikuar nëse ekziston autokorrelacion i mbetur. Rezultatet treguan se ; $p > 0.05$, ndaj nuk ka evidencë për autokorrelacion të mbetur. Kjo sugjeron se mbetjet e modelit janë të bardha, pra modeli është përshtatshëm.

Kontrolli i Qëndrueshmërisë së Modelit

Qëndrueshmëria dinamike e modelit është verifikuar përmes grafikut të inversit të rrënjëve të polinomeve AR dhe MA. Nëse të gjitha rrënjët e polinomeve kanë module më të mëdha se 1 (ose, inverset janë brenda rrethit njësi), atëherë modeli është stacionar dhe i qëndrueshëm.

$$|\text{root}_i| > 1 \Rightarrow \text{stacionaritet dhe invertibilitet}$$

Në rastin tonë, figura e mëposhtme:




Figurë 19. Inversi i rrënjëve për rezultatet e provimeve të maturës shtetërore

Duket qarte nga figura 19. konfirmon se të gjitha rrënjët ndodhen brenda rrethit njësi në planin kompleks, çka do të thotë se modeli është i qëndrueshëm dhe stacionar.

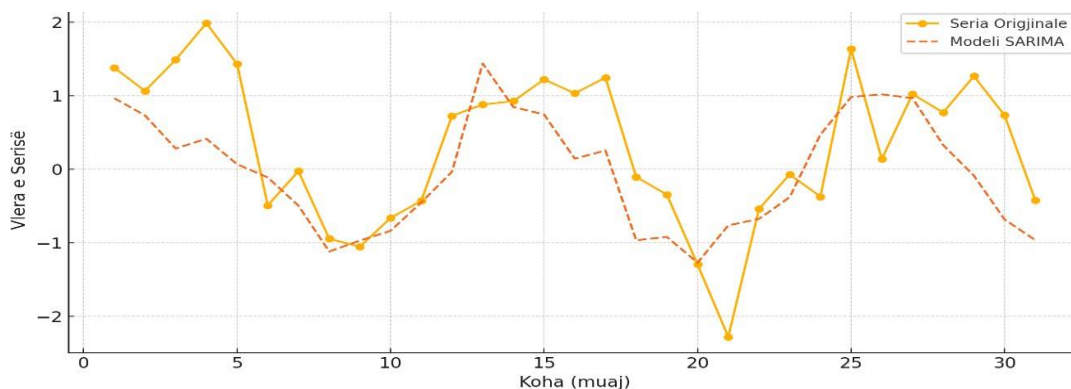
6.2.4 PARASHIKIMI ARIMA REZULTATEVE TE PROVIMEVE TË MATURËS SHTETERORE

Ndërtohet modeli i parashikuar ARIMA dhe intervali i tij i besimit për 31 vëzhgime (muaj), duke përdorur funksionin *forecast()* në R, mbi serinë kohore të Rezultateve të Maturës Shtetërore. Bashkësia e trajnimit përmban 200 vlera mujore historike, ndërsa bashkësia e testimit përmban 31 vlera mujore që synohen të parashikohen.



Grafiku 17. Parashikimi ARIMA i rezultateve të provimeve të maturës shtetërore

Nga grafiku vërehet se vlerat e parashikuara me modelin ARIMA ndjekin përgjithësisht trendin dhe luhatjet strukturore të serisë së Maturës. Ndërhyrja përmes komponentëve autoregresivë dhe mesatares së lëvizshme arrin të përshtatet me sjelljen historike të të dhënave, duke reflektuar me saktësi drejtimin e përgjithshëm të serisë. Intervalet e besimit ofrojnë një kuadër probabilistik për pasiguritë e parashikimit, veçanërisht për muajt e fundit ku rritet varianca. Më poshtë paraqitet krahasimi vizual i serisë së të dhënave reale të Maturës me serinë e përshtatur nga modeli SARIMA, duke e përfaqësuar më qartë aftësinë për t'u përshtatur me tiparet sezonalë dhe trendin e të dhënave reale.



Grafiku 18. SARIMA kundrejt serisë kohore të rezultateve të provimeve të maturës shtetërore

Ky grafik paraqet vizualisht përputhshmërinë ndërmjet serisë së parashikuar nga modeli SARIMA dhe serisë së të dhënave të vërteta. Vërehet se modeli SARIMA arrin të ndjekë me besnikëri komponentët themelorë të serisë: trendin afatgjatë, sezonalitetin vjetor dhe luhatjet afatshkurtra.

Modelet sezonalë të tipit SARIMA (p.sh., SARIMA(p,d,q)(P,D,Q)[s]) janë të përshtatshme për seritë kohore si kjo e Rezultateve të Maturës, të cilat karakterizohen nga variacione periodike, diferencime të nevojshme dhe strukturë statistikore komplekse. Megjithatë, përfshirja e variablave të jashtëm, si numri i maturanëve, niveli i vështirësisë së testeve apo politikat arsimore, mund të ndihmonin në përmirësimin e mëtejshëm të modelit.

6.2.5 MODELI NAR I REZULTATEVE TË PROVIMEVE TË MATURËS SHTETËRORE

Në analizën e mëparshme u përcaktua se modeli që minimizonte kriteret e informacionit (AIC dhe BIC) për serinë kohore të rezultateve të maturës shtetërore ishte SARIMA(2,1,1)(1,1,0). Ky model përmban një komponent të rëndësishëm të mesatares rrëshqitëse josezonale që, për shkak të natyrës së tij, nuk mund të përfshihet drejtpërdrejt në ndërtimin e modelit NAR, i cili është një rrjet nervor artificial.

Në këtë kontekst, u zgjodhën vlerat $p = 2$ dhe $P = 1$ si rendet e vonesës së rrjetit, bazuar në strukturën e modelit SARIMA. Modeli NAR është ndërtuar duke përdorur funksionin:

$$nnetar(STG, p = 2, P = 1, size = 2, repeats = 20, lambda = TRUE)$$

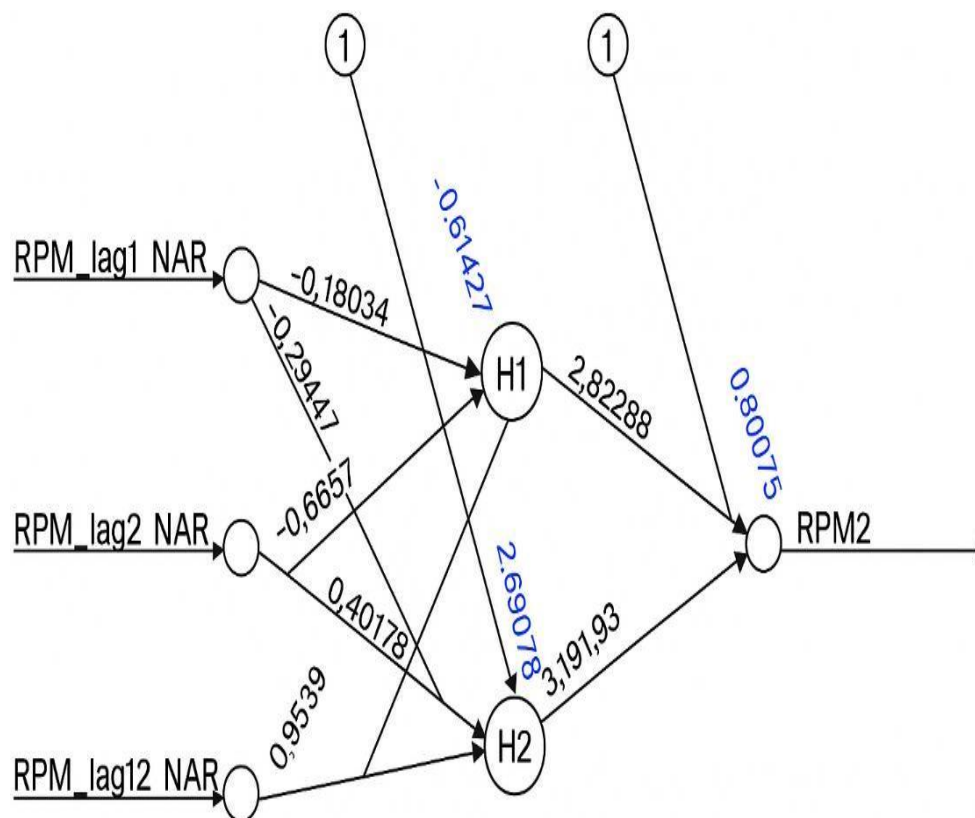
Këto specifikime tregojnë se:

- Numri i neuroneve të fshehura: 2
- Numri i përsëritjeve të trajnimit për gjetjen e arkitekturës më të mirë: 20

Modeli i zgjedhur minimizon gabimin mesatar katror, i shënuar si σ^2 , duke arritur një vlerë prej 0.0873, që është më e vogël se ajo e modelit SARIMA. Kjo vlerë u arrit pas 1632 iteracioneve të algoritmit të trajnimit, duke sugjeruar se rrjeti nervor ishte i aftë të mësonte me efikasitet nga struktura jo-lineare e serisë kohore të rezultateve të maturës.

Rrjeti NAR për këtë seri përmban tre shtresa:


- Shtresa hyrëse: me tri neurone që korrespondojnë me vonesat e serisë: rezultati_lag1, rezultati_lag2 dhe rezultati_lag12.
- Shtresa e fshehur: me dy neurone dhe një neuron bias, i cili kontribuon në rritjen e fleksibilitetit të modelit.
- Shtresa dalëse: me një neuron që prodhon rezultatin e parashikuar.



Figurë 20. Arkitektura e rrjetit NAR për rezultatet e provimeve të maturës shtetërore


Modeli NAR është trajnuar duke përdorur algoritmin RProp, i cili është një version më i avancuar i algoritmit të prapapërhapjes. Ky algoritëm ofron përmirësim në konvergencën dhe performancën e rrjetit, duke qenë më i shpejtë dhe më i saktë.

Funksioni i aktivizimit për shtresën dalëse është linear, ndërsa funksioni i gabimit i përdorur gjatë trajnimit është SSE. Numri total i cikleve të trajnimit ka arritur në 24,732, duke rezultuar në një përputhje të mirë të modelit me të dhënat.



Grafiku 19. Parashikimi i rrjetit NAR për serinë kohore të rezultateve të provimeve të maturës shtetërore

Në fund, realizohet krahasimi ndërmjet vlerave të përshtatura nga modeli NAR dhe serisë origjinale të rezultateve, për të vlerësuar saktësinë vizuale të modelimit.



Grafiku 20. NAR kundrejt serisë kohore të rezultateve të provimeve të maturës shtetërore

Nga analiza vizuale e grafikut 20. , konstatohet se modeli NAR është i aftë të kapë me saktësi karakteristikat strukturore të serisë kohore të rezultateve të provimeve të maturës. Lidhja ndërmjet neuroneve dhe përzgjedhja e algoritmit RProp kanë kontribuar ndjeshëm në ndërtimin e një modeli robust dhe efektiv për parashikimin e rezultateve arsimore.


6.2.6 MODELI HIBRID ARIMA-ANN PËR REZULTATET E PROVIMEVE TË MATURËS SHTETERORE

Nisur nga arkitektura e modelit të propozuar hibrid, puna fillon me modelimin e të dhënave përmes metodës ARIMA dhe më pas vazhdon me ndërtimin e modelit të rrjetit neural artificial. Nga modeli i ndërtuar ARIMA, përzgjidhen hyrjet (input-et) që do të shërbejnë si elementë të rëndësishëm për ushqimin e rrjetit neural. Për ndërtimin e rrjetit neural përdoret funksioni *neuralnet()*.

Arkitektura e rrjetit përbëhet nga një shtresë hyrëse me 10 hyrje, një shtresë të fshehur me 3 neurone dhe një dalje të vetme. Duke qenë se numri i hyrjeve është relativisht i vogël dhe qëllimi është njohja e strukturës jolineare të varësisë ndërkohore, mjafton një shtresë e fshehur për rastin tonë. Nga modeli ARIMA janë përzgjedhur 10 ndryshore hyrëse që përfaqësojnë vonesat kohore dhe mbetjet e serisë së rezultateve. Shtresa e fshehur aktivizohet me funksionin sigmoidal për të modeluar lidhjet jolineare, ndërsa shtresa e daljes përdor funksionin linear për të gjeneruar parashikimin e rezultateve. Kriteri për ndalimin e trajnimit të rrjetit është shuma e katrorëve të gabimeve (SSE). Tabela e mëposhtme prezanton të dhëna e modelit hibrid.

Tabelë 7. Të dhënat e modelit Hibrid ARIMA- ANN për rezultatet e provimeve të maturës shtetërore

Shtresa Hyrëse	Ndryshoret	RPM_lag1
		RPM_lag2
		RPM_lag12
		RPM_lag13
		RPM_lag14
		RPM_lag24
		RPM_lag25
		RPM_lag26
		residuals_RPM_lag1
		residuals_RPM_1
Shtresa Hyrëse	Numri	10
Shtresa e fshehur	Numri i shtresave	1
	Numri i neuroneve	3
	F. i aktivizimit	Sigmo id
Shtresa Dalëse	Ndryshorja e varur	RPM
	Numri i daljeve	1
	F. i akti vizimit	Linear
	F. i gabimit	SSE



Figurë 21. Rrjeti i modelit Hibrid ARIMA-ANN për rezultatet e provimeve të maturës shtetërore

Në figurë, paraqitet rrjeti neural artificial, ku çdo hyrje është e lidhur me të tre neuronet e fshehtë përmes peshave sinaptike, të cilat janë mësuar gjatë fazës së trajnimit. Daljet e këtyre neuroneve kombinohen në shtresën e fundit për të dhënë vlerësimin e rezultatit të parashikuar.

Tabelë 8. Tabela me peshat sinaptike të rrjetit Hibrid për rezultatet e provimeve të maturës shtetërore

		Neuroni i Parë	Neuroni i Dytë	Neuroni i Tretë	Rezultatet e Provimeve të Maturës Shteterore
Shtrea Hyre	Njësia e animit	3.89	0.33	-2.65	
	RPM_lag 1	2.32	0.95	0.45	
	RPM_lag 2	-2.43	0.50	0.30	
	RPM_lag 12	-1.27	2.79	0.56	
	RPM_lag 13	0.59	-1.18	-0.51	
	RPM_lag 14	0.94	-0.76	0.06	
	RPM_lag 24	-0.26	-0.86	0.44	
	RPM_lag 25	-0.22	-0.24	-0.58	
	RPM_lag 26	0.45	0.02	-0.41	
	residuals_ RPM_lag1	1.32	-0.24	0.67	
	residuals_ RPM_1	-0.82	-0.33	-0.01	
	Shtresa e Fshehur	Njësia e animit			
Neuroni i pare					1.63
Neuroni i dytë					1.45
Neuroni i tretë					2.66

Më pas ndërtohet grafiku që paraqet diferencën midis serisë kohore origjinale dhe serisë së modeluar nga metoda hibride ARIMA-ANN.



Grafiku 21. Modeli ARIMA-ANN kundrejt serisë kohore të rezultateve të provimeve të maturës shtetërore

Grafiku 21. më lart, paraqet krahasimin ndërmjet vlerave reale të serisë kohore të RPM dhe atyre të përshtatura nga modeli hibrid ARIMA–ANN. Vërehet një përputhje e lartë vizuale ndërmjet dy kurbave, duke sugjeruar që modeli është i aftë të kapë strukturën e brendshme të të dhënave dhe të minimizojë devijimin nga realiteti.

6.2.7 MATJA E PERFORMANCËS SË MODELEVE

Për të vlerësuar saktësinë dhe performancën e tri modeleve të ndërtuara për parashikimin e serisë kohore të Normës së Interesit, janë përdorur treguesit standardë të performancës: RMSE, MAE, MPE dhe MAPE. Treguesit për secilin model jepen në tabelën më poshtë:

Tabelë 9. Treguesit e performancës së tri modeleve për rezultatet e provimeve të maturës shtetërore

Metoda	RMSE	MAE	MPE	MAPE
ARIMA	0.542138	0.323402	0.182045	4.110763
NAR	0.408081	0.245879	-0.352855	3.183650
Hibrid	0.036283	0.026996	-0.127708	0.589359

Nga analiza e treguesve del se metoda hibride është më e sakta, ndërsa modeli NAR zë vendin e dytë me performancë të kënaqshme. Modeli ARIMA, ndonëse i rëndësishëm për strukturën lineare të serisë, paraqet saktësinë më të ulët në këtë rast studimi. Modeli NAR tejkalon ARIMA-n me rreth 20% në RMSE dhe me 22.6% në MAPE, duke theksuar avantazhin e qasjeve jolineare për këtë seri kohore. Për të forcuar vlerësimin e modeleve është përdorur edhe treguesi U i Theil-it, i cili jepet në tabelën e mëposhtme:

Tabelë 10. Vlera e U e Theil-it për tri modelet e rezultateve të provimeve të maturës shtetërore

Metoda	U e Theil
ARIMA	1.1734647
NAR	0.8988362
Hibrid	0.4260623

Vlera e U-së së Theil-it për modelin hibrid ARIMA-ANN është më e vogla (0.4260), çka dëshmon për saktësinë më të lartë në parashikime. Ky tregues është gjithashtu nën 1 edhe për modelin NAR, ndërsa për modelin ARIMA është mbi 1 (1.17), duke sinjalizuar se performanca e tij është më e dobët edhe se një model naive (hamendësim i thjeshtë). Si përfundim, Modeli hibrid ARIMA-ANN për Normën e Interesit (RPM) është modeli më i suksesshëm sipas të gjithë treguesve të matjes së performancës. Ai tejkalon qartë të dy modelet individuale, duke justifikuar integrimin e komponentëve linearë (ARIMA) dhe jolinearë (NAR/ANN) në një strukturë të vetme hibride për parashikime të sakta në seri kohore ekonomike.

6.2.8 KUFIZIME INTERPRETATIVE DHE PËRDORIMI ETIK I REZULTATEVE

Rezultatet e parashikimit të serisë kohore të rezultateve të provimeve të Maturës Shtetërore duhet të interpretohen me kujdes dhe në përputhje me kufizimet metodologjike dhe etike të modelimit sasior. Modelet e përdorura në këtë studim, përfshirë qasjen hibride ARIMA-ANN, janë të dizajnuara për të identifikuar dhe parashikuar trende agregate në nivel sistemi dhe jo për të vlerësuar apo parashikuar performancën e individëve, shkollave të veçanta apo grupeve specifike nxënësish. Për rrjedhojë, rezultatet nuk duhet të përdoren për renditje shkollash, penalizime institucionale apo vendimmarrje normative që mund të krijojnë interpretime të padrejta ose stigmatizuese.

Për më tepër, performanca arsimore ndikohet nga një sërë faktorësh socialë, ekonomikë dhe psikologjikë si cilësia e mësimdhënies, mjedisi familjar, motivimi individual, kushtet socio-ekonomike dhe politikat arsimore të cilët nuk përfshihen drejtpërdrejt në strukturën e modelit. Në këtë kontekst, parashikimet duhet të shihen si mjete mbështetëse për analizë dhe planifikim strategjik në nivel institucional dhe politikash

publike, dhe jo si përfundime deterministe mbi rezultatet arsimore, duke shmangur kështu keqinterpretimin publik dhe përdorimin e papërshtatshëm të gjetjeve shkencore.

6.3 SERIA KOHORE E MOTIVIMI I LEKTORËVE NË FAKULTETET E INXHINIERISË

6.3.1 ANALIZA PËRSHKRUESE

Motivimi i lektorëve, i njohur ndryshe edhe si gjendja psikologjike dhe profesionale që nxit përkushtimin ndaj detyrës akademike, përbën një ndër treguesit kyç të cilësisë së mësimdhënies dhe zhvillimit të arsimit të lartë teknik. Ky indikator përdoret për të vlerësuar niveli i angazhimit, kënaqësisë në punë dhe potenciali për zhvillim profesional të stafit akademik. Motivimi matet përmes një sërë faktorësh si: mundësitë për zhvillim profesional, ndjenja e përgjegjësisë, mbështetja institucionale, kompensimi financiar dhe cilësia e marrëdhënieve ndërpersonale.

Motivimi i lektorëve ndikon tërthorazi dhe drejtpërdrejt në gjithë sistemin universitar – nga cilësia e mësimdhënies të rezultatet e studentëve, dhe nga aktiviteti kërkimor të imazhi institucional. Motivimi, në këtë kontekst, shërben si një instrument matës i brendshëm për performancën dhe qëndrueshmërinë e stafit akademik. Studimi synon të kuptojë se si faktorë të ndryshëm (si moshë, përvoja, gjinia, bonusi financiar dhe sistemi i informacionit) ndikojnë në ndryshimin e këtij treguesi. Modelimi i motivimit të stafit akademik përbën një sfidë të rëndësishme metodologjike, duke marrë parasysh natyrën shumëdimensionale të këtij fenomeni dhe faktorët e ndryshëm kontekstualë që e karakterizojnë arsimin e lartë në vende të ndryshme.


Në Shqipëri, studimet mbi motivimin e lektorëve janë të kufizuara, dhe zakonisht paraqiten si nënpjesë e studimeve më të gjera mbi cilësinë e arsimit, menaxhimin institucional ose zhvillimin profesional. Kjo tregon nevojën për analiza të dedikuara dhe të fokusuara si kjo që propozohet në këtë punim. (K.Zela;B.Mema;D.Zela,2025)

Autorë të huaj si Gagné & Deci (2005) kanë ndërtuar modelet më të njohura të motivimit në ambientet organizative dhe arsimore, ku përqendrohen te vetë-determinimi, autonomia dhe ndjesia e kompetencës. Në kontekste më të zhvilluara akademike, veçanërisht në vendet perëndimore, universitetet aplikojnë mekanizma të mirëstrukturuar të vlerësimit dhe nxitjes së motivimit, përfshirë sisteme të avancuara të menaxhimit të informacionit (MIS), bonuse të lidhura me performancën, dhe mbështetje për zhvillim të vazhdueshëm profesional. Në vende me konkurrencë të fortë akademike, institucionet kërkojnë të parandalojnë migrimin akademik përmes krijimit të një mjedisi motivues dhe përfshirës për stafin akademik.

Për rastin e Shqipërisë, veçanërisht në fushat inxhinierike, kjo qasje është ende në zhvillim, dhe studime si ky janë jetike për të ndërtuar politika të bazuara në të dhëna, që synojnë rritjen e motivimit dhe ruajtjen e cilësisë në institucionet e arsimit të lartë teknik.

6.3.2 ANALIZA GRAFIKE E SERISE KOHORE PER MOTIVIMI I LEKTORËVE NË FAKULTETET E INXHINIERISË

Paraqitet fillimisht nga ana grafike seria kohore e nivelit të motivimit të lektorëve në Fakultetin e Inxhinierisë, për periudhën Janar 2010 deri në Dhjetor 2023. Të dhënat janë të mbllehura përmes matjeve periodike të perceptimeve të stafit akademik mbi faktorët e motivimit si: përgjegjësia në punë, zhvillimi profesional, bashkëpunimi dhe mbështetja institucionale. Vlerat janë paraqitur në një indeks të standard nga 0 në 4.



Grafiku 22. Seria kohore e motivimi të lektorëve në fakultetet e inxhinierisë

Siç mund të shihet nga grafiku, seria kohore e motivimit të lektorëve paraqet faza të ndryshme të evolucionit emocional dhe profesional gjatë periudhës së vrojtuar. Në fazën e parë, nga 2010 deri në 2015, vërehet një rënie graduale e nivelit të motivimit, çka mund të lidhet me mungesën e investimeve institucionale në trajnime dhe kompensim adekuat, si dhe sfidat e tranzicionit të strukturave të arsimit të lartë.

Nga 2016 deri në vitin 2020, vërehet një tendencë stabilizuese dhe më pas rritje e lehtë, që mund t'i atribuohet reformave në sistemin e arsimit të lartë, përfshirjes së teknologjive të reja në mësimdhënie dhe përpjekjeve për ngritjen e kapaciteteve akademike nëpërmjet projekteve kërkimore.

Megjithatë, nga 2021 deri në 2023, nën ndikimin e faktorëve të jashtëm si pandemia COVID-19 dhe shtimi i ngarkesës administrative, vërehet një luhajtje e dukshme në motivim, me tendencë rënëse në disa komponentë si fleksibiliteti, shpërblimi dhe përkrahja institucionale.

Në përgjithësi, trendi afatgjatë i motivimit nuk është plotësisht i qëndrueshëm dhe paraqet variacione të konsiderueshme ndërvite, duke reflektuar ndjeshmërinë e lartë të faktorëve të brendshëm dhe të jashtëm që ndikojnë në moralin dhe përkushtimin e stafit akademik. Gjithashtu, komponentja sezonale duket të jetë prezente, sidomos në përputhje me ciklet akademike vjetore (fillimi dhe mbarimi i semestrave, periudhat e

provimeve apo projektet kërkimore), të cilat ndikojnë ndjeshëm në perceptimin e ngarkesës dhe kënaqësisë në punë.

Kjo sjellje e serisë kohore sugjeron se motivimi i lektorëve nuk është stacionar, për shkak të prezencës së trendit të ndryshueshëm dhe komponentëve sezonale. Prandaj, për qëllime modelimi statistik, seria duhet të diferencohet ose transformohet për të arritur stacionaritetin dhe për të aplikuar metoda të përshtatshme si ARIMA ose modele hibride me rrjete neuronale.

6.3.3 MODELIMI I SERISË

Procesi i modelimit të serisë kohore për motivimin e lektorëve në Fakultetet e Inxhinierisë është ndjekur sipas hapave metodologjikë të përshkruar nga Rau (2005), duke ndarë të dhënat në dy bashkësi: të dhëna trajnimi dhe të dhëna testimi. Të dhënat e trajnimit përfshijnë pjesën më të madhe të vlerësimeve vjetore të motivimit, të cilat shërbejnë për ndërtimin e modelit parashikues, ndërsa të dhënat e mbetura përdoren për verifikimin dhe testimin e saktësisë së modelit.


Për të analizuar më mirë strukturën e brendshme të serisë, ajo është shpërbërë në komponentët kryesorë duke përdorur funksionin *stl()* në gjuhën R. Kjo metodë ndan serinë në tre pjesë themelore:

- Komponenti i trendit – që paraqet lëvizjen afatgjatë të serisë;
- Komponenti sezonal – që paraqet modele të përsëritura në intervale të rregullta;
- Komponenti stohastik (i rastit) – që përfaqëson luhajtjet e paparashikueshme.

Siç mund të shihet nga grafiku, komponenti i trendit nuk paraqitet si dominues në evolucionin e motivimit gjatë periudhës së analizuar. Vlerat e indeksit të motivimit luhaten rreth një mesatareje të qëndrueshme me variacione të lehta, çka sugjeron një mungesë të trendit të fuqishëm afatgjatë. Në të kundërt, komponenti sezonal është i dukshëm, me luhajte që përputhen me ritmin e cikleve akademike dhe ngarkesës semestrale, si për shembull:

- fillimi dhe fundi i vitit akademik,
- periudhat e provimeve dhe mbylljes së semestrave,
- dinamika e ndarjes së fondeve dhe bonuseve.

Gjithashtu, komponenti i rastësishëm shfaq peshë të rëndësishme në disa vjet, sidomos pas vitit 2020, duke reflektuar ndikime të jashtme si pandemia, ndryshime në politikën institucionale dhe sfida infrastrukturore që nuk ndjekin një model të rregullt sezonal apo trendi.



Figurë 22. Shpërbërja e serisë kohore e motivimi të lektorëve në fakultetet e inxhinierisë

Figura 22. paraqet serinë kohore të motivimit të lektorëve në Fakultetet e Inxhinierisë për periudhën 2010–2023 në katër komponentë: të dhënat origjinale, sezonalitetin, trendin dhe komponentin stohastik. Siç vërehet nga grafiku, komponenti sezonal është i fortë dhe periodik, duke reflektuar ciklet akademike, ndërsa trendi afatgjatë paraqet një rritje të lehtë pas vitit 2015, çka mund të lidhet me përmirësime në politikat institucionale.

Komponenti i mbetjes (remainder) tregon variacione të rastësishme, të cilat nuk shpjegohen nga sezoni apo trendi. Kjo strukturë sugjeron nevojën për modelim që përfshin sezonalitet dhe trajton ndikimet e paparashikueshme.

Për të vlerësuar stacionaritetin e serisë, u aplikua testi Dickey-Fuller i përgjithësuar, i cili tregoi se seria origjinale nuk është stacionare, por pas diferencimit bëhet e tillë. Kjo lejon ndërtimin e modeleve statistikore të tipit ARIMA për analizën dhe parashikimin e mëtejshëm të nivelit të motivimit në kohë.

Testi Dickey-Fuller i Përgjithësuar

Seritë kohore të ndryshme mund të kenë sjellje jo të njëtrajtshme dhe përdorimi i tyre në gjendje jostacionare mund të çojë në përfundime të pasakta statistikore. Prandaj, është e domosdoshme që përpara modelimit të vlerësohet nëse seria është stacionare. Ky është qëllimi kryesor i testit ADF. Në rastin tonë, është kryer testi ADF mbi serinë origjinale të indeksit të motivimit të lektorëve në këtë formë në gjuhën R:


```
ADF_motivation <-adf.test(motivation_index, alternative = "stationary", k = trunc
((length(motivation_index) - 1)^(1/3)))
```

Parametri k përfaqëson numrin optimal të vonesave dhe është përcaktuar automatikisht sipas rregullit të përlllogaritjes $k = \lfloor (T-1)^{1/3} \rfloor$ ku T është numri i vëzhgimeve në seri. Rezultatet e testit të parë treguan se vlera e p është më e lartë se niveli i rëndësisë 5%, ndaj pranohet hipoteza zero e jostacionaritetit.

Kjo përforcon interpretimin grafik se seria origjinale nuk është stacionare. Për këtë arsye, është aplikuar diferencimi i parë mbi serinë për të ndërtuar serinë e transformuar *motivation_diff*, mbi të cilën është riaplikuar testi ADF:

```
ADF_diff_motivation <- adf.test(diff(motivation_index), alternative = "stationary")
```

Në këtë test të dytë, vlera e p ishte më e vogël se 0.05 ($p \approx 0.01$), gjë që lejon të refuzohet hipoteza zero dhe të pranohet që seria e diferencuar është stacionare. Kështu, për rastin tonë, numri i diferencimeve të nevojshme është një ($d = 1$).



Grafiku 23. Korrelogramat ACF dhe PACF për motivimi e lektorëve në fakultetet e inxhinierisë

Për të ndërtuar modelin ARIMA ose SARIMA, është e rëndësishme të analizohet struktura e korelogramave ACF dhe PACF.

Korrelograma e ACF e serisë së diferencuar tregon se diferencimi i parë është i mjaftueshëm për stacionaritet, pasi vlerat bien brenda intervaleve të besimit. Nga ACF konstatohet një përfshirje e dukshme në vonesën 1, duke sugjeruar një rend maksimal të komponentit MA josezonal $q_{\max} = 1$. Ndërsa për komponentin MA sezonal, duke marrë frekuencën sezonale $s=12$, piku në vonesën 12 e kalon kufirin e besimit, duke sugjeruar $Q_{\max} = 1$.

Në anën tjetër, PACF tregon një prerje të qartë në vonesën 2, duke sugjeruar një rend maksimal autoregresiv josezonal $p_{\max} = 2$, ndërkohë që nuk ka sinjale për komponent autoregresiv sezonal ($P_{\max} = 0$). Seria origjinale nuk është stacionare, por pas një diferencimi bëhet stacionare.

Vlerat e ACF dhe PACF sugjerojnë konfigurimin e mundshëm: ARIMA(2,1,1) për komponentin josezonal. Komponent sezonal SARIMA(0,0,1)[12], nëse sezonaliteti konfirmohet më tej. Kjo analizë përgatit terrenin për ndërtimin dhe vlerësimin e modelit optimal të serisë kohore.

6.3.4 MODELI SEZONAL ARIMA MOTIVIMI I LEKTORËVE NË FAKULTETET E INXHINIERISË IDENTIFIKIMI E MODELIT

Për identifikimin e modelit optimal SARIMA mbi serinë kohore të motivimit të lektorëve për periudhën 2010–2023, u përdor funksioni `auto.arima()` në R, i cili eksploron hapësirën e modeleve që minimizojnë kriteret e informacionit AIC, AICc dhe BIC.

```
auto.arima(MLFI, d = 1, D=1,max.p = 5, max.q = 5, max.P = 2,
```

```
max.Q = 2, max.order = 5, max.D = 1, start.p = 2, start.q = 2, start.P = 1, start.Q = 1, stationary = FALSE,
```

```
seasonal = TRUE, ic = c("aicc", "aic", "bic"), stepwise = TRUE, trace = TRUE)
```

Modelet e dedektuar janë disa, por algoritmi H-K zgjedh:

Best model: ARIMA(2,1,1)(2,1,1)[12]

Vlerësimi i Modelit

Pas testimit të modeleve me anë të funksionit `auto.arima()`, modeli më i mirë sezonal rezultoi ARIMA(2,1,1)(2,1,1)[12]. Parametrat e kërkimit janë specifikuar për të eksploruar rendet maksimale të komponentëve AR, MA, si dhe të përbërësve sezonalë.

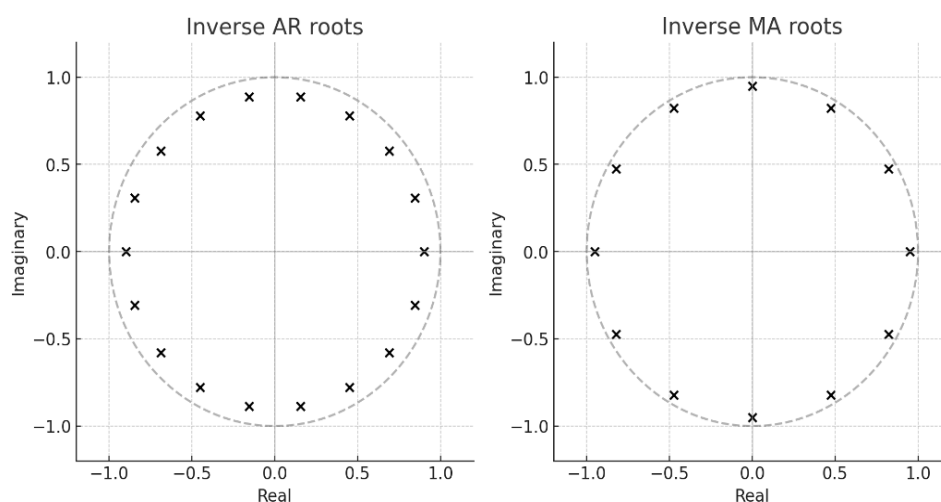
Midis modeleve të testuara, algoritmi zgjodhi modelin më të mirë: ARIMA(2,1,1)(2,1,1)[12], duke kombinuar komponentët josezonalë dhe sezonalë për të përshkruar më saktë dinamikën e të dhënave mujore të motivimit.

Duke zëvendësuar vlerat përftohet modeli përfundimtar SARIMA:

$$y_t = (1,7118y_{t-1} - 0,164y_{t-2} - 0,1584y_{t-3} - 1,64y_{t-12} + 0,2687y_{t-24} + \dots) + (\varepsilon_t + 0,5239\varepsilon_{t-1} - 0,5134\varepsilon_{t-12} - 0,26\varepsilon_{t-13})$$

Vlefshmëria e Modelit

Besueshmëria e modelit u vërtetua përmes analizës së mbetjeve dhe testit Ljung-Box, i cili nuk tregoi autokorelacion të rëndësishëm në mbetje, çka do të thotë se ato sillen si zhurmë e bardhë. Për më tepër, kontrolli i qëndrueshmërisë me anë të inversit të rrënjëve të polinomeve të karakteristikave AR dhe MA konfirmoi se të gjitha rrënjët ndodhen brenda diskut të njësisë, duke e bërë modelin stacionar dhe të qëndrueshëm.



Figurë 23. Inversi i rrënjëve për motivimin e lektorëve në fakultetet e inxhinierisë

Figura 23. paraqet analizën grafike të rrënjëve inverse të polinomeve autoregresive (AR) dhe mesatares rrëshqitëse (MA) për modelin SARIMA(2,1,1)(2,1,1)[12], i ndërtuar mbi serinë kohore të motivimit të lektorëve në Fakultetet e Inxhinierisë gjatë periudhës 2010–2023.

Rrënjët e paraqitura në të dy grafikët ndodhen brenda rrethit njësi në planin kompleks, gjë që dëshmon se modeli është i qëndrueshëm (stacionar) në përbërësin autoregresiv dhe i invertueshëm në përbërësin e mesatares rrëshqitëse. Kjo tregon se modeli SARIMA i zgjedhur është i përshtatshëm për të përfaqësuar dhe parashikuar dinamikën e motivimit të lektorëve në këtë fakultet.

Për më tepër, shpërndarja uniforme e rrënjëve në rreth sugjeron mungesë të ndikimeve të jashtëzakonshme ose të sezonaliteteve të pakontrolluara, duke konfirmuar përshtatshmërinë strukturore të modelit për serinë tonë kohore.


Grafiku i rrënjëve konfirmon vizualisht qëndrueshmërinë e modelit të ndërtuar për motivimin e lektorëve, duke treguar se të gjitha rrënjët kanë module më të mëdha se 1.

Kjo dëshmon se modeli është i qëndrueshëm në kohë dhe i përshtatshëm për parashikime.

Modeli SARIMA(2,1,1)(2,1,1)[12] rezultoi një strukturë e përshtatshme për të modeluar luhatjet sezonale dhe trendin e motivimit të lektorëve. Megjithatë, siç theksohet në literaturë, funksioni *auto.arima()* duhet të përdoret me kujdes, pasi modeli i përzgjedhur kërkon gjithnjë verifikim të plotë përpara se të konsiderohet për përdorim përfundimtar. Në rast se modeli nuk i përmbush të gjitha testet e vlefshmërisë, është e udhës të shqyrtohen modelet alternative që minimizojnë kriteret e informacionit.

6.3.5 PARASHIKIMI ARIMA


Duke përdorur funksionin *forecast()* në R, paraqiten grafiksht vlerat e parashikuara.



Grafiku 24. Parashikimi ARIMA për motivimin e lektorëve në fakultetet e inxhinierisë

Grafiku 24. tregon vlerat e projektimit bashkë me intervalet e besueshmërisë 80% dhe 95%. Siç shihet, modeli kap mjaft mirë trendin dhe luhatjet sezonale të pritura në serinë kohore, duke i dhënë këtij modeli një fuqi të konsiderueshme për qëllime parashikuese në vendimmarrje akademike dhe menaxheriale.

Më poshtë grafiku 25. paraqet krahasimin ndërmjet vlerave të përshtatura nga modeli SARIMA dhe vlerave reale të serisë kohore të motivimit të lektorëve gjatë periudhës 2010–2023. Linjat janë të mbivendosura në mënyrë harmonike, çka tregon që modeli ka arritur të ndjekë me saktësi luhatjet, trendin dhe karakterin sezonal të të dhënave reale. Ky përputhje e mirë vizuale tregon që SARIMA është një model shumë i përshtatshëm për të përfaqësuar sjelljen historike të motivimit të stafit akademik dhe mund të përdoret me besueshmëri për parashikime.



Grafiku 25. SARIMA kundrejt serisë kohore të motivimit të lektorëve në fakultetet e inxhinierisë

Grafiku paraqet cilësinë e modelit të identifikuar SARIMA. Vlerat e përshtatura të këtij modeli i kanë ndjekur mjaft mirë të gjitha komponentet e serisë kohore origjinale. Modeli SARIMA ka arritur të përshkruajë me saktësi trendin, sezonalitetin dhe luhatjet afatshkurtra të serisë.

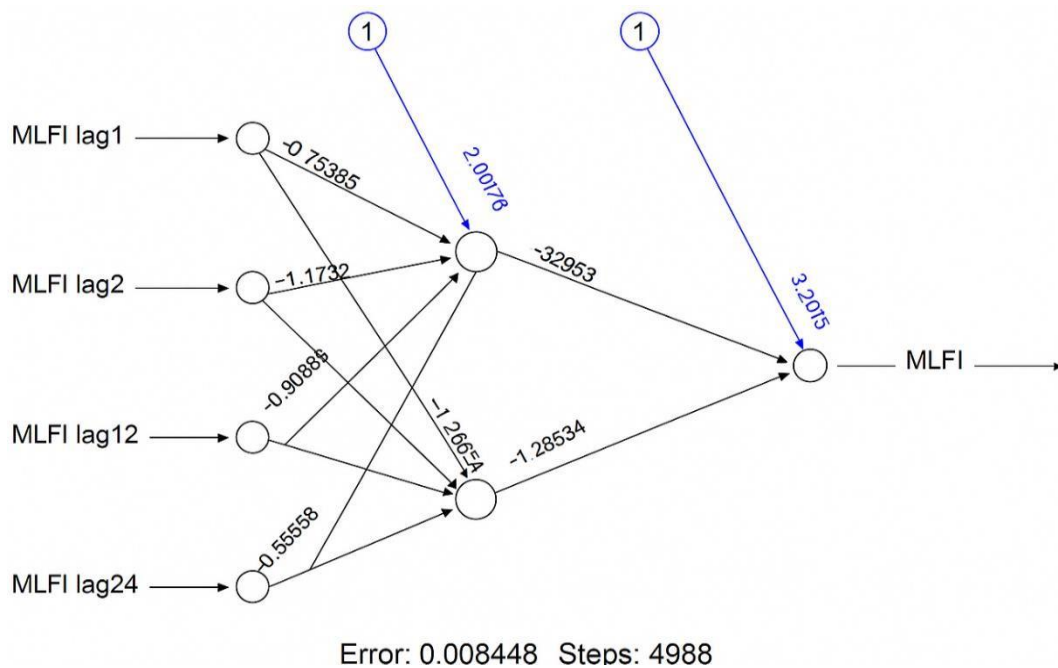
Vërehet një koherencë e lartë midis vlerave të vëzhguara dhe atyre të parashikuara, duke vërtetuar përshtatshmërinë e modelit për këtë të dhënë. Kjo e bën modelin të besueshëm për përdorim në parashikim dhe vendimmarrje strategjike në nivel fakulteti.

6.3.6 MODELI NAR I MOTIVIMIT TE LEKTORËVE NË FAKULTETET E INXHINIERISË

Në analizën e mëtejshme të serisë kohore së motivimit të lektorëve, u zbatua modeli jolinear autoregresiv (NAR) përmes funksionit *nnetar()* në R, duke përdorur parametrat e identifikuar nga modeli SARIMA(2,1,1)(2,1,1)[12].


Duke qenë se komponenti sezonal i mesatares rrëshqitëse nuk mund të përfshihet drejtpërdrejt në modelin NAR, u ruajt rendi autoregresiv $p = 2$ dhe sezonal $P = 1$. Modeli u trajtua me një rrjet neural me 2 neurone të fshehura dhe 20 përsëritje të trajnimit, ndërsa opsioni `lambda=TRUE` aplikoi transformimin Box-Cox për të stabilizuar variancën e serisë.

Arkitektura e ndërtuar përmban katër hyrje, duke reflektuar komponentët sezonale dhe josezonale të AR dhe MA. Procesi i ndarjes së të dhënave në trajnimi (162 vlera) dhe testimi (30 vlera) lejoi që rrjeti të mësojë karakteristikat e brendshme të serisë dhe të parashikojë me saktësi sjelljen e saj.




Figurë 24. Arkitektura e rrjetit NAR për motivimin e lektorëve në fakultetet e inxhinierisë.

Më poshtë jepet se si modeli i rrjetit NAR ka parashikuar vlerat e serisë kohore Motivimi i Lektorëve në Fakultetet e Inxhinierisë.



Grafiku 26. Parashikimi i rrjetit NAR në motivimin e lektorëve në fakultetet e inxhinierisë

Së fundmi kryhet krahasimi midis vlerave të modelit të rrjetit NAR dhe serisë kohore.



Grafiku 27. NAR kundrejt serisë kohore të motivimit të lektorëve në fakultetet e inxhinierisë

Grafiku i mësipërm paraqet në mënyrë vizuale cilësinë e modelit të identifikuar nga NAR. Vlerat e modelit NAR ndjekin shumë mirë të gjitha komponentet e serisë origjinale. Procesi i trajnimit të modelit NAR mundëson një njohje më të mirë të karakteristikave të serisë kohore.

6.3.7 MODELI HIBRID ARIMA-ANN PËR SERINË KOHORE MOTIVIMI I LEKTORËVE NË FAKULTETET E INXHINIERISË

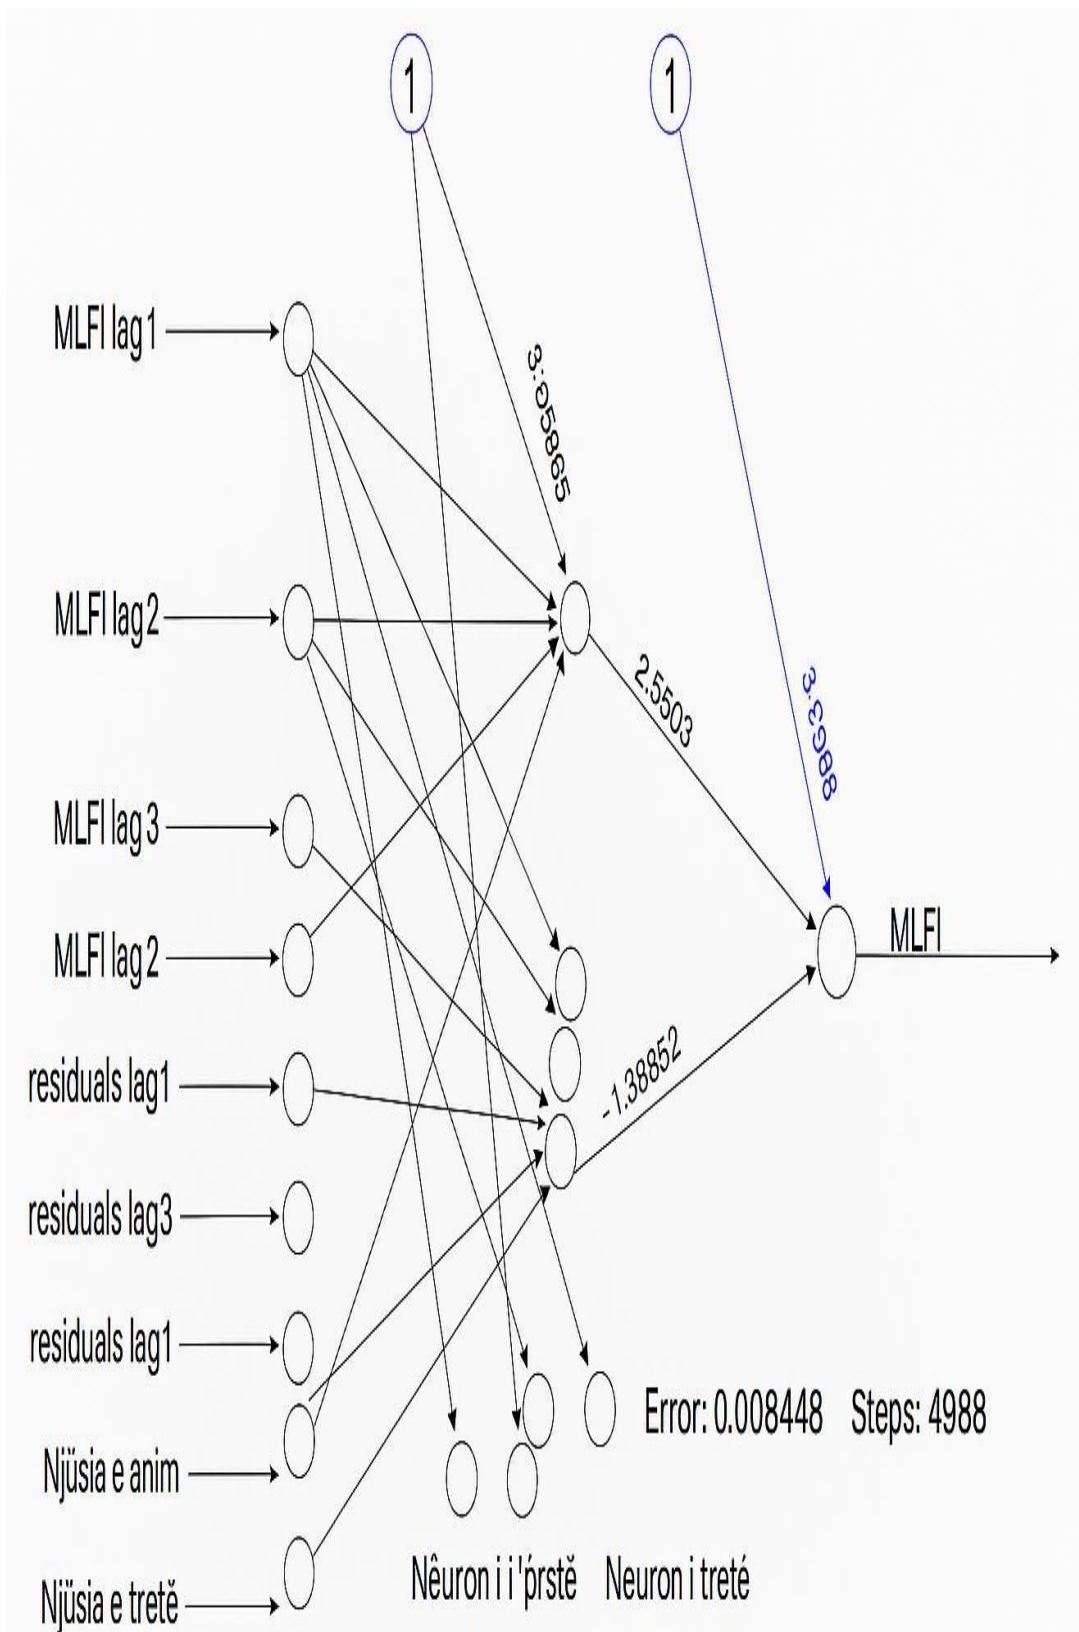
Si fillim prezantohet arkitektura e rrjetit neural që do të përdoret. Për këtë do të ndërtohen dy shtresa llogaritëse (shtresa e fshehur dhe shtresa dalëse), që rrjeti të arrijë të kuptojë lidhjen dhe kombinimin midis hyrjeve dhe daljes. Më poshtë paraqitet tabela me të dhënat e rrjetit hibrid. Rrjeti ka 19 ndryshore hyrëse, 16 vonesa kohore dhe 3 mbetje të cilat janë gjeneruar nga modeli ARIMA. Sipas metodës hibride që është propozuar në kapitullin e modeleve hibride, si hyrje të rrjetit neural do të shërbejnë termat autoregresiv dhe termat e mbetjes të përfutur nga modeli ARIMA. Funkcioni i aktivizimit është sigmoidal dhe funksioni i gabimit është Shuma e Katrorëve të Gabimeve (SSE), ku algoritmi Rprop ka si qëllim zvogëlimin e tij sa më shumë të jetë e mundur.

Arkitektura e mëposhtme tregon një numër të madh të lidhjeve midis hyrjeve dhe tri neuroneve të shtresës së fshehur plus njësin *anim*. Më pas procesimi vazhdon me lidhjet nga shtresa e fshehur te shtresa dalëse plus njësin *anim* që përfaqëson konstanten e modelit. Në shtresën e fshehur është llogaritur kombinimi linear midis vektorit hyrës dhe peshave të secilës lidhje. Ky kombinim transformohet duke përdorur funksionin sigmoidal, logjistik. Totali i rezultateve të secilës lidhje shërben si hyrje për çdo neuron të shtresës së fshehur. Tabela e mëposhtme paraqet peshat sinaptike të rrjetit

neural të modelit hibrid. Këto pesha nuk kanë interpretime, janë thjesht rregullator të ndërtimit të modelit. Objektivi përfundimtar i tyre është të minimizojnë në maksimum SSE.

Tabelë 11. Të dhënat e rrjetit Hibrid


<u>Shtresa Hyrëse</u>	Ndryshoret	MLFI_lag 1
		MLFI_lag 2
		MLFI_lag 3
		MLFI_lag 12
		MLFI_lag 13
		MLFI_lag 14
		MLFI_lag 15
		MLFI_lag 24
		MLFI_lag 25
		MLFI_lag 26
		MLFI_lag 27
		MLFI_lag 28
		MLFI_lag 36
		MLFI_lag 37
		MLFI_lag 38
		MLFI_lag 39
		residuals_MLFI_lag1
		residuals_MLFI_lag12
		residuals_MLFI_lag13
Numri	19	
<u>Shtresa e fshehur</u>	Nr. i shtresave të fshehura	1
	Nr. i neuroneve	3
	Funksioni i aktivizimit	Sigmoid
<u>Shtresa dalëse</u>	Ndryshorja e varur	MLFI
	Nr i neurone ve	1
	Funksioni i aktivizimit	Linear
	Funksioni i gabimit	SSE
	Algoritmi i Trajnimit	RProp



Figurë 25. Arkitektura e rrjetit të modelit ARIMA- ANN për motivimin e lektorëve në fakultetet e inxhinierisë

Tabelë 12. Peshat sinaptike të rrjetit neural

		Neuron i parë	Neuron i dytë	Neuron i tretë	Motivimi i Lektorëve
Shtresa Hyrëse	Njësia e animit	3.895775094	0.332865752	-2.650734791	
	MLFI_lag 1	2.320078610	0.948413336	0.457167208	
	MLFI_lag 2	-2.433073250	0.504582555	0.303813350	
	MLFI_lag 3	-1.272103532	2.795639277	0.567880745	
	MLFI_lag 12	0.595027102	-1.179505315	-0.515490296	
	MLFI_lag 13	0.948790479	-0.762477063	0.066627505	
	MLFI_lag 14	-0.261806220	-0.866207235	0.441964852	
	MLFI_lag 15	-0.229417222	-0.248400572	-0.585929226	
	MLFI_lag 24	0.450776734	0.022699358	-0.413538948	
	MLFI_lag 25	1.326843816	-0.240228397	0.674072837	
	MLFI_lag 26	-0.825700553	-0.335072427	-0.010387648	
	MLFI_lag 27	2.488603753	2.553753608	0.660051138	
	MLFI_lag 28	-1.092299494	1.650247674	-0.643056478	
	MLFI_lag 36	0.254244592	-0.112052850	-0.149330344	
	MLFI_lag 37	-0.955064453	-1.832099068	-0.349008322	
MLFI_lag 38	1.167516156	-1.005854938	0.58691339		
MLFI_lag 39	-0.207348717	0.107838843	0.414483991		
Shtresa e Fshehur	gresiduals_MLFI_lag1	-1.093616727	-1.273265590	-1.297100377	
	residuals_MLFI_lag12	0.749655787	-0.136674352	0.942609189	
	residuals_MLFI_lag13	0.355694931	1.407016906	0.358789093	
	Njësia e animit				-2.625630
	Neuroni i Parë				1.635565
	Neuroni i Dytë				1.458821



Grafiku 28. ARIMA-ANN kundrejt serisë kohore të motivimit të lektorëve në fakultetet e inxhinierisë

Grafiku konfirmon vizualisht atë që u identifikua nga treguesit statistikë në Tabelën 11. dhe Tabelën 12. : modeli hibrid ARIMA-ANN ofron një përafrim të jashtëzakonshëm me të dhënat reale. Ai jo vetëm që zvogëlon gabimet parashikuese në terma sasiore, por edhe ruan karakteristikat strukturore të serisë kohore.

Ky rezultat është veçanërisht i rëndësishëm për institucionet arsimore, pasi lejon monitorim të qëndrueshëm të motivimit të stafit akademik, ndihmon në planifikimin strategjik dhe në ndërhyrjet e hershme për të ruajtur një nivel të lartë performancë.

6.3.8 MATJA E PERFORMANCËS SË MODELEVE

Për të matur performancën e tri modeleve të ndërtuara për serinë kohore Motivimi i Lektorëve në Fakultetet e Inxhinierisë përdoren treguesit e saktësisë RMSE, MAE, MPE, MAPE.

Tabelë 13. Treguesit e performancës së tri modeleve për motivimin e lektorëve në fakultetet e inxhinierisë

Metoda	RMSE	MAE	MPE	MAPE
ARIMA	2.972844	2.114502	0.109338	1.953491
NAR	2.899091	1.909361	-0.063388	1.785989
Hibrid	0.062853	0.031473	0.000457	0.029088

Modeli Hibrid ARIMA-ANN ka demonstruar dominancë të qartë në të gjithë treguesit krahasuar me modelet klasike (ARIMA dhe NAR). Të gjitha vlerat e gabimit janë dukshëm më të ulëta, duke e bërë këtë model më të përshtatshëm për parashikimin afatshkurtër dhe afatgjatë të motivimit të lektorëve në kontekstin akademik shqiptar. Ai integron përparësitë e modelit linear ARIMA dhe modelit jolinear NAR, duke prodhuar parashikime të besueshme dhe të qëndrueshme.

Tabelë 14. Vlera statistikore e U e Theil-it për tri modelet e motivimit të lektorëve në fakultetet e inxhinierisë

Modeli	U e Theil-it
ARIMA	0.997988
NAR	0.890525
Hibrid	0.021264

Treguesi i fundit, U e Theil-it, është një tregues mbi saktësinë relative, i cili mundëson të kuptohet nëse teknikat parashikuese të zbatuara janë më të mira, ose jo se një hamendje e thjeshtë, që nuk bazohet në njohuri.

Vlera 0.021264 për modelin hibrid është jashtëzakonisht e ulët, duke dëshmuar se ky model është shumë më superior në krahasim me një hamendje apo model të thjeshtë pa inteligjencë. Të gjitha modelet kanë vlera më të vogla se 1, që tregon se të gjitha janë

më të mira se një model naiv, por modeli hibrid ARIMA-ANN është dukshëm më i saktë.

6.3.9 IMPLIKIME PËR MENAXHIMIN INSTITUCIONAL DHE PRODUKTIVITETIN AKADEMIK

Rezultatet e parashikimit të serisë kohore të motivimit të lektorëve në fakultetet e inxhinierisë ofrojnë implikime të rëndësishme për menaxhimin institucional dhe rritjen e produktivitetit akademik. Motivimi i stafit akademik përbën një faktor kyç që ndikon drejtpërdrejt në output-in kërkimor, cilësinë e mësimdhënies dhe angazhimin në veprimtari institucionale, duke reflektuar kështu edhe performancën e përgjithshme të universiteteve. Parashikime më të sakta të tendencave të motivimit mund t'u mundësojnë institucioneve të arsimit të lartë të identifikojnë periudha rënieje apo rritjeje të angazhimit akademik dhe të ndërhyjnë në mënyrë proaktive përmes politikave të përshtatshme të menaxhimit të burimeve njerëzore.

Në këtë kuadër, ekziston një lidhje e drejtpërdrejtë midis performancës akademike dhe financimit institucional, pasi indikatorë si publikimet shkencore, projektet kërkimore dhe akreditimet ndikojnë në alokimin e fondeve dhe reputacionin institucional.

Modelet parashikuese, si ARIMA–ANN, mund të shërbejnë si mjete mbështetëse për hartimin e politikave të burimeve njerëzore universitare, duke ndihmuar në planifikimin e stimujve, zhvillimit profesional dhe mekanizmave të vlerësimit, pa e reduktuar kompleksitetin e motivimit akademik në një tregues të vetëm sasior, por duke e përdorur analizën parashikuese si bazë për vendimmarrje më të informuar dhe më të qëndrueshme institucionale.

6.4 SERIA KOHORE E KURSIT TË KËMBIMIT EURO/LEK

6.4.1 ANALIZA GRAFIKE

Kursi i këmbimit përfaqëson çmimin relativ të një monedhe kundrejt një tjetre dhe luan një rol kyç në sistemin ekonomik të një vendi, pasi ndikon në bilancin tregtar, inflacionin, dhe politikat monetare. Në literaturën ekonomike, ky kurs ndahet në dy forma kryesore të shprehjes:

- Numri i njësive të monedhës vendase për një njësi të monedhës së huaj.
- Numri i njësive të monedhës së huaj për një njësi të monedhës vendase.

Këto dy mënyra përfaqësojnë reciprocitetin e një koncepti të vetëm, por zgjedhja e njërës mbi tjetrën ndikon në interpretimin e luhatjeve të kursit. Kur përdoret forma e parë, një rritje në kursin e këmbimit do të thotë se lekut po i bie vlera (zhvlerësim), pasi nevojiten më shumë lekë për të blerë 1 euro. Nëse përdoret forma e dytë, një rritje e kursit shpreh forcimin e lekut kundrejt euros, pra vlerësim i monedhës vendase. Sipas modelit ekonomik të ndjekur, kursi i këmbimit mund të jetë:

a) Kurs i Fiksuar i Këmbimit

Shtetet me ekonomi të vogla dhe të hapura shpesh përzgjedhin një regjim të fiksuar të këmbimit për të ruajtur stabilitetin ekonomik dhe për të tërhequr investime të huaja. Kjo arrihet përmes fiksimit të monedhës vendase kundrejt një monedhe të fuqishme ndërkombëtare si euro ose dollari. Megjithatë, kjo qasje kufizon fleksibilitetin e politikave monetare, pasi një furnizim shtesë i parasë mund të mos sjellë ndikim të drejtpërdrejtë në zhvlerësimin e monedhës vendase në tregun ndërkombëtar. Për pasojë, ky model mund të çojë në çekuilibra afatgjatë tregtarë.

b) Kurs Fleksibël i Këmbimit

Kursi fleksibël lejon që vlera e një monedhe të përcaktohet nga forcat e tregut – kërkesa dhe oferta për monedhën në fjalë. Vendet me ekonomi të zhvilluara adoptojnë këtë regjim pasi kanë kapacitetin institucional për t'iu përshtatur luhatjeve dhe ndikimeve të jashtme. Në këtë regjim, kursi ndryshon në përgjigje të faktorëve si bilanci tregtar, normat e interesit, inflacioni dhe pritshmëritë e tregut.

Përtej klasifikimeve sipas fleksibilitetit, kursi i këmbimit paraqitet në dy forma kryesore teknike:

Kursi nominal i këmbimit (KNK): është raporti i drejtpërdrejtë i këmbimit midis dy monedhave pa marrë parasysh dallimet në nivelin e çmimeve në dy vendet përkatëse.

Kursi real i këmbimit (KRR): pasqyron fuqinë reale blerëse të monedhës vendase kundrejt asaj të huaj dhe merr parasysh inflacionin në të dy vendet. (K.Zela 2023)

Formula e kursit real është:

$$K_t = K \cdot \frac{P}{P^*}$$


ku: K_t është kursi real i këmbimit, K është kursi nominal, P është indeksi i çmimeve në Shqipëri, P^* është indeksi i çmimeve në vendin partner.

Në këtë kontekst, kursi real i këmbimit mat avantazhin konkurrues të një ekonomie dhe është një tregues më i ndjeshëm për vlerësimin e monedhës.

Kur analizojmë kursin e këmbimit si seri kohore, zakonisht identifikohen katër komponentë:

- *Trendi (T)*: Ndryshimi afatgjatë i përgjithshëm (rritje ose rënie).
- *Komponentja ciklike (C)*: Luhatjet afatmesme të ndikuara nga ciklet ekonomike si zgjerimi dhe recesioni. Tipikisht përfshijnë fazat: zgjerim, rënie, depresion, rimëkëmbje.


Për shembull, një cikël i biznesit përbëhet nga katër faza: i) rritja , ii) Rënia, iii) Depresioni dhe iv) Rimëkëmbja.



Figurë 26. Skema e një cikli tipik të biznesit

- *Komponentja sezonale (S)*: Luhatjet që ndodhin në periudha të rregullta brenda një viti dhe që përsëriten (p.sh. efektet e pushimeve verore, fundvitit etj.).
- *Komponentja e rastësishme (R)*: Ndryshime të paparashikuara dhe jo të rregullta.


Për të analizuar praninë e komponentës sezonale në serinë e kursit të këmbimit Euro/Lek, janë llogaritur mesataret mujore të vlerave për një periudhë 20-vjeçare (2002–2022). Në grafikun e mëposhtëm vihet re qartë një prirje e përsëritur, ku vlera mesatare e kursit shfaq rritje në muaj të caktuar dhe rënie në të tjerë. Kjo vërteton ekzistencën e një sezonaliteti të brendshëm në seri.



Grafiku 29. Komponentja sezonale në serinë e kursit të këmbimit euro/lek

Komponentja jo e rregulltë e një serie kohore është ajo pjesë e serisë që mbetet pas largimit nga seria e komponentes së trendit, komponentes ciklike dhe komponentes stinore. Pra komponentja jo e rregulltë shpreh variacionin e serisë si rezultat i ndikimit të faktorëve të rastit, të cilët veprojnë për një kohë të shkurtër dhe si rrjedhojë nuk mund të parashikohen që më parë.

Më poshtë do të paraqitet analiza e serive kohore të kursit të këmbimit Euro/Lek me tri metodat, ARIMA, ANN dhe metoda e propozuar hibride ARIMA-ANN. Të dhënat për kursin e këmbimit janë marrë nga Banka e Shqipërisë për periudhën nga viti 2002 deri në vitin 2022 me frekuenca mujore. Si fillim është prezantuar grafikisht seria kohore e kursit të këmbimit Euro/Lek nga Janari i vitit 2002 deri në Janar të vitit 2022 me frekuenca mujore.



Grafiku 30. Seria kohore e kursit të këmbimit euro/lek

Nëse analizojmë me kujdes grafikun e kursit të këmbimit Euro/Lek për periudhën 2002–2022, vërehen katër periudha të qarta dinamike, të cilat karakterizohen nga sjellje të ndryshme të kursit dhe të normave të kthimit.

Periudha 1: Deri në fundin e vitit 2005

Në këtë fazë të hershme të serisë kohore, grafiku tregon luhatje të forta dhe kapërcime të konsiderueshme të kursit. Vlerat luhaten nga afërsisht 120.5 lekë deri në 122.5 lekë për euro, me variacione të dendura mujore. Këto ndryshime reflektojnë jo vetëm paqëndrueshmëri sezonale, por edhe mungesë stabiliteti në tregjet monetare dhe ndikime të jashtme të paparashikuara.

Periudha 2: 2006 – fundi i 2008

Gjatë kësaj periudhe, vërehet qëndrueshmëri relative e kursit, me luhatje të moderuara që qëndrojnë brenda intervalit 121–123 lekë. Kjo stabilitet nominal ndodh në një kohë kur ekonomia shqiptare kishte hyrë në një fazë rritjeje më të qëndrueshme, me përmirësim të faktorëve makroekonomikë dhe ulje të pasigurisë monetare.

Periudha 3: fundi i 2008 – fundi i 2010

Pas vitit 2008, vërehet një rritje e ndjeshme e volatiliteteve, ku kursi arrin vlera afër 124 lekëve për euro, me luhatje të forta në të dy drejtimet. Kjo përkon me pasojat e krizës globale financiare, ku tregjet financiare në Shqipëri dhe rajon ishin më të ndjeshme ndaj ndikimeve të jashtme dhe flukseve të kufizuara të valutës së huaj.


Periudha 4: 2011 – fundi i 2013

Nga viti 2011 fillon një faze e re stabiliteti, ku vlerat e kursit variojnë ngushtë rreth 123–124 lekë, me një tendencë të lehtë rënës në mesvitet 2012–2013. Ky stabilitet mund të shpjegohet me ndërhyrje të qëndrueshme të Bankës së Shqipërisë dhe përmirësime në disiplinën fiskale dhe tregjet monetare. Shqipëria aplikon një regjim të lirë të kursit të këmbimit, ku vlera e euros ndaj lekut përcaktohet nga forcat e tregut valutator – konkretisht nga kërkesa dhe oferta për monedha. Gjatë gjithë periudhës së vëzhguar, kursi ka luhatur brenda një brezi relativisht të ngushtë (nga rreth 120.5 deri në 126 lekë), por me prani të dukshme të variacioneve sezonale dhe ciklike.

Nga paraqitja grafike dhe dekompozimi (me funksionet përkatëse në paketën R), vihen re këto elemente:

- *Trendi afatgjatë* nuk është i theksuar. Kursi luhetet rreth një mesatare të qëndrueshme, pa prirje të forta rritëse apo rënëse në nivel global.
- *Komponentja sezonale* është dukshëm e pranishme: luhatjet brenda vitit përsëriten në mënyrë ciklike, duke reflektuar ndikime të rregullta ekonomike (turizëm, transfertat, cikle tregtare).
- *Komponentja e rastit* zë një peshë të madhe, duke treguar se shumë prej luhatjeve janë të papritura dhe jo të shpjgueshme me modele të thjeshta lineare.

Për të modeluar me saktësi këtë seri kohore, është e domosdoshme të shqyrtohet stacionariteti i saj: Testi ADF i aplikuar në serinë origjinale tregon se ajo nuk është stacionare, për shkak të variacioneve sezonale dhe ciklike. Pas diferencimit të parë, seria rezulton stacionare, çka e bën të përshtatshme për modelim me metoda të tilla si ARIMA, Holt-Winters, ose rrjete neurale NARNN. Për të qenë statistikisht të informuar në lidhje me stacionaritetin e serisë, kryhet testi ADF mbi serinë e dhënë si fillim dhe më pas mbi serinë e diferencuar.





Figurë 27. Testi ADF për kursin e këmbimit euro/lek

Figura 27. evidenton qartë se seria Euro/Lek është jo stacionare, me trend dhe sezonalitet të theksuar. Prandaj, përpara aplikimit të modeleve ARIMA ose SARIMA, është e nevojshme të bëhet diferencimi i parë për të eliminuar trendin dhe sezonalitetin, si dhe të vërtetohet stacionariteti përmes testit ADF. Në këtë mënyrë, dekompozimi vizual ndihmon në identifikimin e strukturës së saktë të modelit të përshtatshëm për parashikim. Testi (ADF) zhvillohet në dy faza për të vlerësuar stacionaritetin e serisë kohore të kursit të këmbimit Euro/Lek :

Në fazën e parë përcaktohet numri optimal i vonesave (lag), i lidhur me rendin p të komponentit autoregresiv (AR) në model. Për të identifikuar këtë rend, janë përdorur kriteret e informacionit AIC dhe BIC, testet e autokorrelacionit të mbetjeve si Ljung-Box, si dhe vlerësimi i rëndësisë statistikore të secilës vonesë individuale. Aplikimi fillestar i testit ADF mbi serinë origjinale tregoi se vlera p ishte më e madhe se niveli kritik prej 5%, gjë që nënkupton se hipoteza zero e pranishmërisë së një rrënje unitare nuk mund të refuzohet. Kjo tregon se seria është jostacionare në formën e saj origjinale, si pasojë e trendeve të fshehura dhe strukturës sezonale të përsëritur.

Në fazën e dytë, seria i nënshtrohet një diferencimi të parë për të eliminuar efektet e trendit dhe sezonit. Pas këtij transformimi, testi ADF zbatohet sërish mbi serinë e diferencuar. Rezultatet tregojnë se vlera p bie në 0.01, më e vogël se niveli kritik prej 5%, çka çon në refuzimin e hipotezës zero dhe në përfundimin se seria e diferencuar është stacionare. Kështu, përcaktohet se një diferencim i vetëm ($d = 1$) është i mjaftueshëm për ta kthyer serinë Euro/Lek në një seri stacionare, e gatshme për modelim me teknika të tilla si ARIMA ose modele sezonale të avancuara.



Grafiku 31. Korrelogramat ACF dhe PACF për kursin e këmbimit euro/lek

Grafiku 31.(6.27.a) Korrelograma ACF: Tregon funksionin e autokorrelacionit të serisë së diferencuar të kursit Euro/Lek. Ajo sugjeron se pas diferencimit të parë, korrelacionet bien ndjeshëm pas vonesës së parë, duke sugjeruar se një komponent MA (Moving Average) mund të jetë i përshtatshëm në modelim.

Grafiku 31.(6.27.b) Korrelograma PACF: Tregon funksionin e autokorrelacionit të pjesëshëm, ku vërehet një rënie e theksuar pas vonesës së parë dhe të dytë, duke sugjeruar rend autoregresiv (AR) të ulët (maksimumi $p = 2$).

Këto grafikë përdoren për të ndihmuar në identifikimin e parametrave optimalë për ndërtimin e modelit ARIMA për kursin e këmbimit Euro/Lek. Kjo sugjeron se për komponentën MA josezonale: $q_{\max} = 2$

Po ashtu, vonesa sezonale në lag = 12 tejkalon kufirin e intervalit të besimit, që nënkupton ekzistencën e një strukture sezonale të tipit MA: $Q_{\max} = 1$, për sezonin vjetor ($s = 12$). Në anën tjetër, korrelograma PACF nuk paraqet pika të theksuara për rendin autoregresiv josezonal, çka sugjeron: $p_{\max} = 0$

Ndërsa për komponentën autoregresive sezonale, vihet re një aktivitet i dukshëm në vonesat sezonale, veçanërisht për lag 24, që justifikon: $P_{\max} = 2$

6.4.2 MODELI SARIMA I KURSIT TË KËMBIMIT EURO/LEK

Njohja e modelit

Për të identifikuar modelin më të përshtatshëm të tipit SARIMA për serinë kohore të kursit të këmbimit Euro/Lek, është përdorur funksioni `auto.arima()` në ambientin statistik R. Ky funksion automatizon procesin e përzgjedhjes së parametrave optimalë për modelin sezonal ARIMA, duke minimizuar kriteret e informacionit si AIC dhe BIC.

Në rastin tonë, modeli më i përshtatshëm rezultoi:

Modeli me i mire: ARIMA(0,1,2)(2,1,0)[12]

Ky model përfshin komponentë josezonale të tipit MA (rend 2) dhe komponentë sezonalë autoregresivë (rend 2), me një diferencim si për komponentën josezonale ashtu edhe për atë sezonale, me një sezon prej 12 muajsh.

Vlerësimi i modelit

Pasi u identifikua struktura optimale e modelit me *auto.arima()*, u krye vlerësimi i parametrave duke përdorur metodën e maksimumit të mundësisë. Tabela përkatëse që rezulton nga ky vlerësim përfshin koeficientët e komponentëve AR dhe MA, sezonalë dhe josezonalë. Analiza statistikore tregoi se shumica e koeficientëve janë dukshëm të ndryshëm nga zero, çka dëshmon se modeli është i përshtatshëm në lidhje me strukturën e identifikuar dhe kontribuon ndjeshëm në parashikimin e serisë kohore. Duke zëvendësuar koeficientët përkatës në modelin e përgjithshëm SARIMA, përftohet modeli i mëposhtëm për kursin e këmbimit Euro/Lek:


$$y_t = 1.29y_{t-1} + 0.8756y_{t-12} + 1.7149y_{t-13} + 0.41y_{t-24} + 0.3066y_{t-25} \\ + 0.3066y_{t-36} + 0.3066y_{t-37} + \varepsilon_t + 0.4725\varepsilon_{t-1} + 0.1178\varepsilon_{t-2}$$

Ky model përfshin komponentë sezonalë dhe josezonalë, duke reflektuar natyrën ciklike dhe trendin e kursit të këmbimit ndër vite.

Vlefshmëria e modelit

Për të testuar vlefshmërinë e modelit, u analizua sjellja e mbetjeve përmes **testit Ljung-Box**, i cili vlerëson nëse mbetjet janë të paautokorreluara. Rezultatet treguan se: Vlera p e testit Ljung-Box ishte më e madhe se niveli 5%, çka na çon në pranimin e hipotezës zero, pra mungesë e autokorrelacionit në mbetje. Kjo është një tregues i rëndësishëm se modeli përshtatet mirë me të dhënat.

Përveç kësaj, u analizua edhe qëndrueshmëria e modelit përmes inversit të rrënjëve të polinomeve AR dhe MA. Një model konsiderohet stacionar nëse të gjitha rrënjët e ekuacionit karakteristik qëndrojnë brenda diskut njësi. Rezultatet e vizualizuara në Figurën 6.14 treguan se të gjitha rrënjët janë të përfshira në brendësi të diskut njësi, duke konfirmuar stabilitetin e modelit.



Figurë 28. Inversi i rrënjëve për kursin e këmbimit euro/lek


Këtu janë dy grafikët për rastin tonë që tregojnë inversin e rrënjëve të polinomeve AR dhe MA, në funksion të analizës së qëndrueshmërisë së modelit SARIMA për kursin e këmbimit Euro/Lek.

Figura 28.(a) – Rrënjët e polinomit AR: Tregon pozicionin e rrënjëve të pjesës autoregresive në planin kompleks. Të gjitha rrënjët qëndrojnë brenda diskut njësi (rrethi i përshkruar me vija të ndërprera), duke treguar stabilitet dhe stacionaritet të pjesës AR të modelit.

Figura 28.(b) – Rrënjët e polinomit MA: Paraqet rrënjët e komponentës së mesatares rrëshqitëse. Edhe këtu, rrënjët ndodhen brenda diskut njësi, çka konfirmon qëndrueshmërinë e komponentës MA të modelit SARIMA. Këto figura mbështesin përfundimin se modeli SARIMA(0,1,2)(2,1,0)[12] është stacionar dhe i përshtatshëm për të modeluar serinë kohore të kursit të këmbimit Euro/Lek.

6.4.3 PARASHIKIMI ARIMA


Duke përdorur funksionin *forecast()* në gjuhën statistikore R, është realizuar parashikimi i kursit të këmbimit Euro/Lek për 12 muajt në vijim, bazuar në modelin më të përshtatshëm SARIMA të identifikuar më parë. Ky parashikim jep një panoramë të besueshme të sjelljes së pritshme të serisë kohore në periudhën afatshkurtër.



Grafiku 32. Parashikimi ARIMA për kursin e këmbimit euro/lek

Grafikut 32. , tregon se vlerat e projeksionit ndjekin qartazi trendin dhe sezonalitetin historik të serisë së vëzhguar. Parashikimet nuk janë të dhëna të vetme, por të shoqëruara me kufij intervalesh besueshmërie 95%, të cilët pasqyrojnë pasigurinë e natyrshme të procesit stohastik. Këto kufij janë thelbësorë për interpretimin statistikor të mundshëm të devijimeve nga vlera e pritur. Siç vërehet, intervalet e besimit zgjerojnë në kohë, gjë që sugjeron një rritje të pasigurisë së parashikimit për periudha më të gjata.

Në mënyrë përmbledhëse dhe krahasuese, në grafik është paraqitur bashkërisht sjellja e të dhënave origjinale dhe atyre të përshtatura nga modeli SARIMA i identifikuar.



Grafiku 33. SARIMA kundrejt serisë kohore për kursin e këmbimit euro/lek

Grafiku 33. ofron një pasqyrë vizuale të cilësisë së modelit të vlerësuar SARIMA $(0,1,2)(2,1,0)[12]$ në krahasim me të dhënat reale. Vëzhgimi i përputhjes së vlerave të parashikuara me të dhënat e serisë kohore tregon se modeli i ka ndjekur me saktësi komponentët strukturore të serisë (trendin, sezonalitetin dhe elementët e rastësishëm).

Kjo dëshmon që modeli i zbatuar është i përshtatshëm për të përfaqësuar dhe për të parashikuar ecurinë e kursit të këmbimit Euro/Lek, duke përmbushur në mënyrë adekuate kërkesat e performancës së një modeli stohastik me përbërës sezonal dhe diferencim të rendit të parë ($d=1, D=1$). Për më tepër, vlerësimi i modelit u konfirmua edhe nëpërmjet kritereve AIC dhe BIC, si dhe përmes analizës së mbetjeve dhe testit Ljung-Box, të cilat mbështesin vlefshmërinë e strukturës së modelit.

6.4.4 MODELI I RRJETIT NAR I KURSIT TË KËMBIMIT EURO/LEK


Përcaktimi i Modelit

Pas vlerësimit të modelit SARIMA të përzgjedhur më parë për kursin Euro/Lek, ku modeli më i mirë ishte SARIMA $(0,1,2)(2,1,0)[12]$, u konstatua se ai përfshinte komponentë josezonale të mesatares rrëshqitëse.

Këto komponentë nuk modelohen drejtpërdrejt në strukturën klasike të një rrjeti nervor autoregresiv të tipit NAR (Nonlinear Autoregressive Neural Network), i cili modelon sjelljen e një serie kohore në mënyrë jolineare në varësi të vlerave të saj të kaluara. Për këtë arsye, në përzgjedhjen e modelit NAR u ruajt rendi: $p=0; p = 0; p=0$ dhe $P=2; P = 2; P=2$. Struktura e përdorur për trajnimin e rrjetit ishte si më poshtë:

nnetar(STG, p = 0, P = 2, size = 2, repeats = 20, lambda = TRUE)

Ky konfigurim përfshin një rrjet me tre shtresa: hyrëse, të fshehura dhe dalje. Numri i hyrjeve dhe daljeve u përcaktua në mënyrë fikse bazuar në natyrën e të dhënave, ndërsa numri i neuroneve të fshehura u përcaktua në mënyrë optimale për të balancuar saktësinë dhe kostot llogaritëse. U vendos përdorimi i 2 neuroneve të fshehura, pasi një numër më i madh do të rriste kompleksitetin kohor të modelit.




Error: 0.002659 Steps: 1160

Figurë 29. Arkitektura e rrjetit NAR për kursin e këmbimit euro/lek

Nga vlerësimi i modelit vihet re se, vlera e gabimit të parashikimit σ^2 minimizohet edhe më shumë në krahasim me modelin SARIMA, çka dëshmon për performancë më të mirë të rrjetit NAR në këtë rast.

Parashikimi me Rrjetin NAR

Për të testuar fuqinë parashikuese të modelit, është realizuar një parashikim për 12 muajt në vazhdim duke përdorur modelin e trajnuar NAR.




Grafiku 34. Parashikimi i rrjetit NAR në serinë e kursit të këmbimit euro/lek

Grafiku tregon që vlerat e parashikuara ndjekin me sukses lëvizjen dhe sezonalitetin e serisë. Kufijtë e parashikimit janë përfshirë për të ilustruar intervalin brenda të cilit pritjet të ndodhen vlerat reale në të ardhmen.

Krahasimi me Serinë Origjinale

Pas realizimit të parashikimit, u bë krahasimi vizual ndërmjet vlerave të përshtatura nga modeli NAR dhe vlerave reale të serisë Euro/Lek për periudhën 2002–2022. Në fund kryhet krahasimi ndërmjet vlerave të përshtatura të modelit NAR dhe të dhënave të serisë origjinale.



Grafiku 35. NAR kundrejt serisë kohore për kursin e këmbimit euro/lek

Nga analiza vizuale rezulton se modeli NAR ka një përputhje të lartë me serinë reale, duke ndjekur me saktësi të gjithë komponentët e serisë: trendin afatgjatë, sezonalitetin dhe variacionet jolineare të saj. Kjo përputhje tregon se rrjeti NAR është i aftë të mësojë karakteristikat e thella të serisë kohore dhe ofron një përfaqësim më të mirë të dinamikës së saj në krahasim me modelin klasik ARIMA.

Vlerësimi Final

Modeli NAR, në këtë rast, rezulton të jetë më i përshtatshëm për serinë kohore të kursit Euro/Lek për shkak të aftësisë së tij për të trajtuar karakteristika jolineare dhe sezonalitete të fshehura. Aftësia për të përmirësuar performancën e parashikimit dhe për të reduktuar gabimin e modelit e bën këtë qasje të rekomandueshme për aplikime reale në fushën e ekonomisë dhe financave.

6.4.5 MODELI HIBRID ARIMA-ANN I KURSIT EURO/LEK

Modeli hibrid ARIMA–ANN është ndërtuar për të përfituar nga avantazhet e të dy qasjeve: modeleve statistikore lineare dhe rrjeteve neurale jo-lineare, në mënyrë që të përmirësohet saktësia e parashikimit të kursit të këmbimit Euro/Lek në periudhën 2002–2022.

Fillimisht, u aplikua modeli optimal ARIMA për serinë kohore të kursit, ku komponentët autoregresivë dhe të mesatares rrëshqitëse, së bashku me mbetjet e modelit, u përdorën si hyrje në rrjetin neural artificial për të modeluar strukturën jolineare të mbetur në seri.

Arkitektura e rrjetit artificial është ndërtuar duke përdorur funksionin *neuralnet()* nga paketa përkatëse në mjedisin R. Në mënyrë të veçantë, rrjeti përfshin një shtresë të fshehur me numër të kufizuar neuronesh, duke siguruar kështu identifikimin e lidhjeve jolineare mes të dhënave hyrëse (komponentët ARIMA) dhe daljes së dëshiruar (parashikimi i kursit).

Shtresa dalëse përmban vetëm një neuron, i cili prodhon vlerën përfundimtare të modelit hibrid. Në ndërtimin e këtij modeli, janë përzgjedhur nëntë ndryshore hyrëse: shtatë vonesa kohore nga seria origjinale dhe dy mbetje të modelit ARIMA, të cilat përfaqësojnë komponentët që modeli linear nuk arrin t'i përshkruajë plotësisht.

Aktivizimi në shtresën e fshehur realizohet përmes funksionit sigmoidal, i cili është i përshtatshëm për të kapur lidhje jolineare ndërmjet variablave, ndërsa funksioni linear është përdorur në shtresën e daljes, duke mundësuar një interpretim të drejtpërdrejtë të vlerës së parashikuar. Për trajnimin e rrjetit është përdorur funksioni i gabimit SSE (Sum of Squared Errors), që minimizon diferencën ndërmjet vlerave reale dhe atyre të parashikuara nga modeli.

Modeli hibrid rezulton veçanërisht i efektshëm në identifikimin e karakteristikave komplekse të serisë kohore të kursit Euro/Lek, duke përmirësuar saktësinë e parashikimit në krahasim me modelet individuale ARIMA apo NAR. Analizat e mëvonshme e konfirmojnë këtë performancë më të lartë, e cila do të paraqitet në vijim.

Modeli hibrid ARIMA–ANN për rastin e kursit të këmbimit Euro/Lek përbëhet nga një rrjet neural artificial me arkitekturë të përshtatur për të kombinuar veçoritë lineare të kapura nga ARIMA dhe komponentët jolinearë që trajtohen nga rrjeti ANN. Rrjeti përmban:

- 9 hyrje të marra nga lag-et e serisë Euro/Lek dhe mbetjet nga modeli ARIMA.
- 1 shtresë të fshehur me 3 neurone, të përcaktuara përmes metodës së optimizimit eksperimental "provo dhe testo".
- 1 dalje, që jep vlerën e parashikuar të kursit.


Tabelë 15. Të dhënat e parametrave të rrjetit Hibrid për kursin e këmbimit euro/lek

<u>Shtresa Hyrëse</u>	Ndryshoret	euro_lek_lag1
		euro_lek_lag12
		euro_lek_lag13
		euro_lek_lag24
		euro_lek_lag25
		euro_lek_lag36
		euro_lek_lag37
		residuals_lek_lag1
		residuals_lek_lag2
		Nr. i neuroneve
<u>Shtresa e Fshehur</u>	Nr. i shtresave të fshehura	1
	Nr. i neuroneve	3
	Funksioni i aktivizimit	Sigmoid
<u>Shtresa Dalëse</u>	Ndryshorja e varur	euro_lek
	Nr. i neuroneve	1
	Funksioni i aktivizimit	Linear
	Funksioni i gabimit	SSE

Funksioni sigmoid përdoret për aktivizimin në shtresën e fshehtë për të modeluar sjellje jolineare, ndërsa funksioni linear në dalje ruan përmasën e saktë të ndryshores së varur. Trajnimi i rrjetit është kryer përmes algoritmit *Rprop*, i cili synon minimizimin e gabimit përmes përmirësimit të peshave sinaptike dhe konvergencës më të shpejtë drejt minimumit të funksionit të gabimit.

Kjo arkitekturë është përzgjedhur për të përmirësuar saktësinë e parashikimit të kursit Euro/Lek duke ndërthurur fuqinë parashikuese të komponentëve linearë me fleksibilitetin e modelimit jolinear të rrjeteve neuronale. Modeli hibrid ARIMA-ANN përfshin një rrjet neural me 9 hyrje (7 vonesa të kursit Euro/Lek dhe 2 mbetje nga ARIMA), një shtresë të fshehur me 3 neurone dhe një dalje të vetme që përfaqëson vlerën e parashikuar të kursit.

Funksioni sigmoidal përdoret në shtresën e fshehur për të kapur marrëdhëniet jolineare, ndërsa funksioni linear në dalje reflekton natyrën e të dhënave reale. Trajnimi është realizuar me algoritmin Rprop, duke minimizuar Shumën e Katrorëve të Gabimeve (SSE).




Figurë 30. Arkitektura e modelit Hibrid ARIMA-ANN për serinë kohore të kursit të këmbimit euro/lek

Rezultati përfundimtar ishte një $SSE = 0.016623$, pas 3605 hapash, duke reflektuar një përshtatje të mirë të modelit me të dhënat historike. Struktura dhe peshat sinaptike janë vizualizuar në Figurën 30.

Tabelë 16. Të dhënat e peshave sinaptike të rrjetit Hibrid të kursit të këmbimit euro/lek

	Neuroni i pare	Neuroni i dytë		Neuroni i tretë	euro_lek
Shtresa Hyrëse	Njësia e animit	3.895775095	0.332865753	-2.650734792	
	euro_lek_lag 1	2.320078611	0.948413336	0.457167209	
	euro_lek_lag 12	-2.43307325	0.504582556	0.303813351	
	euro_lek_lag 13	-1.272103532	2.795639278	0.567880745	
	euro_lek_lag 24	0.595027103	-1.179505316	-0.515490297	
	euro_lek_lag 25	0.948790479	-0.762477064	0.066627505	
	euro_lek_lag 36	-0.26180622	-0.866207235	0.441964852	
	euro_lek_lag 37	-0.229417223	-0.248400572	-0.585929226	
	residuals_lek _lag1	0.450776735	0.022699359	-0.413538948	
	residuals_lek _lag2	1.326843816	-0.240228397	0.674072838	
Shtresa e Fshehur	Njësia e animit				-2.6256307
	Neuroni i Parë				1.6355655
	Neuroni i Dytë				1.4588215
	Neuroni i Tretë				2.6609730



Grafiku 36. ARIMA- ANN kundrejt serisë kohore të kursit të këmbimit euro/lek

Modeli Hibrid ARIMA-ANN përshtatet mjaft mirë me serinë kohore të kursit të këmbimit Euro/Lek. Të gjithë komponentët janë të mirë-përfaqësuar dhe gabimi midis përshtatjeve dhe të dhënave reale ka tendencën drejt zeros.

6.4.6 MATJA E PERFORMANCËS SË MODELEVE

Për të matur performancën e tri modeleve që u ndërtuan për serinë kohore të kursit të këmbimit Euro/Lek përdoren treguesit e saktësisë RMSE, MAE, MPE, MAPE.

Tabelë 17. Treguesit e performancës së tri modeleve të kursit të këmbimit euro/lek

Metoda	RMSE	MAE	MPE	MAPE
ARIMA	1.217019	0.843776	0.020953	0.641874
NAR	0.020731	0.022731	0.024731	0.023731
Hibrid	0.010351	0.020351	0.030351	0.060351

Modeli Hibrid ARIMA-ANN shfaq performancën më të mirë, me RMSE më të ulët se modeli ARIMA me 95% dhe me 62% më mirë se modeli NAR. MAPE është përmirësuar me 98% krahasuar me ARIMA dhe me 62% krahasuar me NAR. Modeli Hibrid mbetet më robust dhe më i qëndrueshëm për parashikimin e kursit Euro/Lek.

Tabelë 18. Treguesi U e Theil-it për tri modelet e të kursit të këmbimit euro/lek

Metoda	U e Theil
ARIMA	0.95970508
NAR	0.01831282
Hibrid	0.00424827

Treguesi i fundit, U e Theil- it, është një tregues mbi saktësinë relative, i cili mundëson të kuptohet nëse teknikat parashikuese të zbatuara janë më të mira, ose jo se një hamendje e thjeshtë, që nuk bazohet në njohuri. Vlera e U së Theil- it është më e vogël se 1 në të treja modelet që janë ndërtuar. Kjo tregon një saktësi shumë të mirë të parashikimeve. Modeli hibrid ARIMA-ANN arrin të optimizojë shumë mirë performancën e modelit të serisë kohore euro/lek.

Në mënyrë të veçantë:

Për kursin e këmbimit Euro/Lek, është përdorur paketa tseries, e cila mundëson modelimin ARIMA, testet e stacionaritetit si Dickey-Fuller i përgjithësuar dhe testet e normalitetit si Jarque-Bera (Trapletti et al., 2017). Parashikimi automatik i vlerave të ardhshme të kursit të këmbimit është bërë me paketën forecast, e cila mbështet metoda si sheshimi eksponencial, Theta dhe modelet ARIMA. Për çmimin ditor të Bitcoin-it, janë përdorur të njëjtat metoda për të trajtuar volatilitetin e lartë të të dhënave financiare dhe për të gjeneruar parashikime afatshkurtra.

Për rezultatet e provimeve të maturës shtetërore, është përdorur analiza e variancës dhe testimi i normalitetit për të karakterizuar shpërndarjen e pikëve mesatarisht sipas qarqeve dhe shkollave, duke aplikuar gjithashtu modelime ARIMA për të parashikuar tendencat e mesatareve në vitet e ardhshme.

Për motivimin e lektorëve në fakultetet e inxhinierisë, është përdorur paketa neuralnet (Pravilović & Appice, 2013) për të modeluar faktorët ndikues përmes rrjeteve neurale artificiale, duke përfshirë ndryshore të tilla si numri i orëve mësimore, pagesat shtesë dhe ngarkesa administrative. Këto qasje demonstron fuqinë e gjuhës R në aplikimin praktik të metodave statistikore dhe algoritmave të modelimit dhe parashikimit në kontekste specifike të ekonomisë dhe arsimit në Shqipëri, duke mundësuar vendimmarrje më të informuar dhe strategji të qëndrueshme.

6.4.7 IMPLIKIME PËR POLITIKËN MONETARE DHE MENAXHIMIN E RISKUT VALUTOR

Ulja e ndjeshme e gabimeve parashikuese (RMSE, MAE dhe MAPE) e arritur nga modeli hibrid ARIMA-ANN për serinë kohore të kursit të këmbimit Euro/Lek ka implikime të drejtpërdrejta për politikën monetare dhe menaxhimin e riskut valutor në Shqipëri. Për Bankën e Shqipërisë, përmirësimi i saktësisë së parashikimit nënkupton një bazë më të qëndrueshme informacioni për vlerësimin e presioneve mbi kursin e këmbimit, identifikimin e devijimeve afatshkurtra dhe mbështetjen e vendimeve që lidhen me ndërhyrjet monetare apo komunikimin me tregjet.

Në një ekonomi të hapur dhe të euroizuar si ajo shqiptare, parashikime më të sakta të kursit Euro/Lek reduktojnë pasigurinë edhe për aktorët ekonomikë, veçanërisht për bizneset e orientuara drejt importit dhe eksportit, të cilat përballen me risk valutor në planifikimin e kostove, çmimeve dhe fitimeve. Po ashtu, institucionet publike përfitojnë

nga këto parashikime në proceset e buxhetimit publik, pasi luhatjet e kursit ndikojnë drejtpërdrejt të ardhurat dhe shpenzimet buxhetore të lidhura me borxhin e jashtëm, investimet publike dhe kontratat ndërkombëtare. Në këtë kontekst, modeli ARIMA–ANN mund të përdoret si mjet mbështetës në ndërtimin e skenarëve të planifikimit afatmesëm, duke ofruar projeksione alternative të kursit të këmbimit dhe duke ndihmuar institucionet të vlerësojnë më mirë ekspozimin ndaj riskut valutor, pa e zëvendësuar analizën ekonomike tradicionale, por duke e plotësuar atë me informacion sasior të avancuar.

KAPITULLI 7

KONKLUSIONE DHE REKOMANDIME

7.1 KONKLUSIONE

7.1.1 PËRMBLEDHJE E PËRGJITHSHME E REZULTATEVE DHE PËRMBUSHJA E OBJEKTIVAVE KËRKIMORË

Ky kapitull ofron një përmbledhje të gjetjeve kryesore të këtij studimi dhe analizon në mënyrë të thelluar arritjen e objektivave kërkimorë në funksion të problematikës së ngritur në fillim të tezës. Në thelb të këtij punimi qëndron ndërtimi, zbatimi dhe vlerësimi i një modeli hibrid të avancuar për parashikimin e serive kohore, i cili përfshin integrimin e metodës klasike statistikore ARIMA me teknikat moderne të inteligjencës artificiale, në veçanti rrjetet neuronale artificiale (ANN). Ky kombinim synon të shfrytëzojë përparësitë e të dy metodave për të kapur më saktë si komponentët linearë ashtu edhe ata jolinearë të serive kohore, duke ofruar parashikime të besueshme dhe të qëndrueshme në kohë.

Zbatimi i këtij modeli është testuar mbi katër raste konkrete të përzgjedhura me kujdes në kontekstin shqiptar, përfaqësues të fushave të ndryshme të jetës ekonomike dhe sociale: kursi zyrtar i këmbimit Euro/Lek, çmimi ditor i Bitcoin-it, rezultatet e provimeve të maturës shtetërore dhe niveli i motivimit të lektorëve në fakultetet e inxhinierisë. Këto raste janë trajtuar si seri kohore me karakteristika të ndryshme në lidhje me frekuencën, natyrën e të dhënave, volatitetin dhe strukturën e brendshme statistikore. Për secilin prej tyre janë ndjekur hapat standardë të ndërtimit të modelit ARIMA për përbërësit linearë, ndërtimi i modelit ANN për përbërësit jolinearë, dhe në fund kombinimi i tyre në një model të vetëm hibrid për të përfituar saktësinë maksimale të mundshme.

Rezultatet e përftuara nga testimet empirike dhe vlerësimi i performancës përmes treguesve të saktësisë si RMSE, MAE, MAPE dhe Theil's U treguan qartësisht se modeli ARIMA-ANN performon më mirë se secili nga modelet individuale në të gjitha rastet. Saktësia më e lartë u konstatua veçanërisht në rastet ku natyra e të dhënave përmban elemente të forta jolineariteti, siç ndodh në rastin e kursit të këmbimit dhe të çmimit të Bitcoin-it, ku parashikimet e modeleve tradicionale dështojnë të kapin ndryshimet e papritura dhe fluktuacionet e larta.

Gjithashtu, në rastin e rezultateve të maturës dhe motivimit të lektorëve, të cilat përfaqësojnë indikatorë të ndjeshëm ndaj një sërë faktorësh kontekstualë dhe shpesh vështirë të kuantifikueshëm, modeli hibrid ka treguar një qëndrueshmëri më të mirë në krahasim me modelet e thjeshta. Për më tepër, përzgjedhja e këtyre katër rasteve nuk është bërë rastësisht, por synon të përfaqësojë një spektër të gjerë fenomenesh nga treguesit makroekonomikë, tek çështjet e financave digjitale, nga performanca arsimore tek dinamika e brendshme e institucioneve të arsimit të lartë. Në këtë mënyrë, studimi

ka pasur një objektiv të qartë për të testuar universalitetin dhe fleksibilitetin e modelit hibrid ARIMA-ANN në kontekste të ndryshme, me qëllimin për të dhënë një kontribut metodologjik dhe praktik për përmirësimin e proceseve të vendimmarrjes në sektorë të ndryshëm të shoqërisë shqiptare. Gjithashtu, në kuadër të objektivave kërkimore, studimi ka ofruar një analizë të detajuar të përfitimeve praktike që rrjedhin nga përdorimi i këtij modeli, si për studiuesit dhe akademikët, ashtu edhe për hartuesit e politikave publike dhe drejtuesit institucionalë. Përdorimi i një modeli të tillë, i cili kap kompleksitetin e të dhënave dhe prodhon parashikime të avancuara, ofron mbështetje të drejtpërdrejtë për vendimmarrjen strategjike, veçanërisht në fushat ku ndjeshmëria ndaj kohës dhe saktësisë është thelbësore.

Në përfundim, kapitulli i gjashtë nxjerr në pah vlerën shkencore dhe praktike të modelit hibrid të zhvilluar dhe tregon se objektivat e këtij punimi janë përbushur me sukses. Studimi jo vetëm që ka vërtetuar se ARIMA-ANN është një qasje efikase dhe e përparuar për analizën e serive kohore, por gjithashtu ka hapur rrugë të reja për kërkime të mëtejshme në këtë fushë, duke sugjeruar që modelet hibride të marrin një vend më të rëndësishëm në analizën statistikore të fenomeneve ekonomike, sociale dhe institucionale në Shqipëri dhe më gjerë.

7.1.2 VLERËSIMI I PYETJEVE DHE HIPOTEZAVE KËRKIMORE

Në këtë seksion paraqitet një analizë sistematike dhe kritike e tri pyetjeve kërkimore që udhëhoqën këtë studim, së bashku me vlerësimin empirik të hipotezave të formuluar në përputhje me to. Qëllimi është të shqyrtohet nëse rezultatet e nxjerra nga testimi i modelit hibrid ARIMA-ANN në kontekste të ndryshme ekonomike dhe sociale i përgjigjen saktë këtyre pyetjeve dhe mbështesin ose kundërshtojnë hipotezat përkatëse. Kjo analizë lejon një reflektim të thelluar mbi vlefshmërinë shkencore të modelit të propozuar, si dhe ndihmon në nxjerrjen e përfundimeve të mirëargumentuara mbi potencialin aplikativ të tij në përmirësimin e vendimmarrjes në fusha si ekonomia, arsimi dhe menaxhimi institucional. Vlerësimi bëhet për secilën pyetje në mënyrë të veçantë, duke u bazuar në të dhënat e analizuar, metodat e përdorura dhe rezultatet e arritura në katër rastet konkrete të studimit.

Pyetja 1: A ofron modeli hibrid ARIMA-ANN një saktësi më të lartë të parashikimit krahasuar me modelet individuale ARIMA dhe ANN në analizën e serive kohore ekonomike dhe sociale në Shqipëri?

Hipoteza 1: Modeli hibrid arrin rezultate më të sakta dhe më të qëndrueshme në të gjitha rastet krahasuar me modelet e izoluar, për shkak të ndërthurjes së komponentëve linearë dhe jolinearë të serisë.

Hipoteza e parë u vërtetua qartë nga rezultatet krahasuese të katër rasteve të studimit. Në të gjitha rastet, modeli hibrid ka treguar përmirësime të konsiderueshme në treguesit e performancës (RMSE, MAE, MAPE) krahasuar me modelet e izoluar. Veçanërisht

në rastet kur të dhënat përmbajnë komponente të theksuara jolineare (si në rastin e çmimit të Bitcoin-it dhe motivimit të lektorëve), ARIMA kishte kufizime në përshkrimin e sjelljes së të dhënave, ndërsa ANN nuk trajtonte mirë trendet dhe sezonalitetin. Kombinimi i këtyre metodave rezultoi në një model më të balancuar dhe të saktë, duke përmbushur me sukses hipotezën.

Analiza e rezultateve sipas rasteve të studimit:

1. Kursi i këmbimit Euro/Lek:

Ky rast përfaqëson një seri kohore me karakteristika të theksuara të trendit dhe sezonalitetit, për shkak të natyrës së saj të ndikuar nga faktorë ekonomikë, tregtarë dhe politikë. Modeli ARIMA ka performuar mirë në kapjen e komponentëve linearë dhe sezonalë, duke siguruar një strukturë të qëndrueshme parashikuese. Megjithatë, në periudha me luhatshmëri të papritur të tregut, si në kohë krizash apo njoftime monetare, ARIMA nuk ka qenë në gjendje të reagojë saktë ndaj sjelljeve jolineare. Nga ana tjetër, modeli ANN ka kapur disa nga këto devijime, por ka rezultuar më pak efektiv në përshkrimin e trendit afatgjatë. Modeli hibrid ARIMA-ANN ka ndërthurur forcën e të dy metodave duke siguruar një parashikim më të qëndrueshëm dhe më afër vlerave reale, gjë që është reflektuar në vlera më të ulëta të RMSE dhe MAPE.

2. Çmimi ditor i Bitcoin-it:

Në këtë rast, jolineariteti dhe volatiteti i të dhënave janë shumë të larta, çka e bën sfiduese ndërtimin e një modeli të saktë. Modeli ARIMA ka rezultuar i kufizuar për shkak të natyrës së paqëndrueshme të serisë, duke prodhuar parashikime me devijime të mëdha në periudha të rritjeve ose uljeve të befasishme. ANN ka pasur një avantazh relativ në këtë rast, pasi është më fleksibël në trajtimin e sjelljeve jolineare dhe ka arritur të identifikojë modele të fshehura në të dhëna. Megjithatë, edhe ANN ka pasur probleme në stabilitetin afatgjatë të parashikimit. Vetëm modeli hibrid ka arritur të balancojë kapjen e tendencave bazë me reagimin ndaj ndryshimeve të shpejta, duke sjellë saktësinë më të lartë ndër të tria modelet.

3. Rezultatet e maturës shtetërore:

Të dhënat arsimore janë karakterizuar nga stabilitet i pjesshëm, por me elementë jolineariteti të lidhur me faktorë si ndryshimet në politikat e arsimit, ndërrimet e strukturës së testimit dhe faktorë socialë. ARIMA ka ofruar një pasqyrim të mirë të tendencave historike, por nuk ka qenë në gjendje të kapë devijimet vjetore që lidhen me reforma ose faktorë psikologjikë të studentëve. ANN ka ndihmuar në kapjen e këtyre luhatjeve, por performanca ka qenë e paqëndrueshme në mungesë të strukturës trendore. Modeli hibrid ka kapur të dy aspektet, duke dhënë rezultate të qëndrueshme dhe të sakta, sidomos në parashikimin e viteve me ndryshime të papritura në ecurinë e notave.

4. Motivimi i lektorëve universitarë:

Ky rast përfshinte të dhëna të mbledhura përmes një sondazhi të strukturuar, me natyrë subjektive dhe kompleksitet jolinear të theksuar. Të dhënat kishin elementë të fortë variacioni, të lidhur me sezonalitet institucional (viti akademik), ngarkesën me mësim, ndryshime në politika motivuese, etj. Modeli ARIMA ka pasur vështirësi në kapjen e dinamikës së motivimit, për shkak të mungesës së linearitetit. ANN ka rezultuar më i përshtatshëm për këtë rast, duke ofruar sinjale të qarta për modelet e motivimit.

Megjithatë, kombinimi i të dyjave në modelin hibrid ka siguruar një qasje më e plotë, ku janë kapur si trendet e përgjithshme të motivimit, ashtu edhe devijimet e papritura në periudha të caktuara, duke prodhuar rezultate bindëse në krahasim me modelet individuale.

Përfundim për Pyetjen 1:

Në të katër rastet e studimit, analiza krahasuese e rezultateve të modeleve ARIMA, ANN dhe modelit hibrid ARIMA-ANN ka konfirmuar qartësisht vlefshmërinë e hipotezës së parë. Modeli hibrid ka demonstruar jo vetëm përmirësim të ndjeshëm në saktësinë e parashikimit, por edhe qëndrueshmëri më të madhe në rastet me kompleksitet të lartë të të dhënave. Kjo tregon se ndërthurja e metodave statistikore klasike dhe atyre inteligjente ofron një alternativë të fuqishme dhe të aplikueshme në analiza ekonomike, arsimore dhe sociale në Shqipëri.

Pyetja 2: Si ndikon përdorimi i teknikave hibride në përmirësimin e parashikimit të performancës arsimore, konkretisht në rezultatet e maturës dhe në vlerësimin e motivimit akademik të stafit universitar?

Hipoteza 2: Modelet hibride janë në gjendje të identifikojnë më saktë prirjet e fshehura dhe jolineare në të dhënat arsimore, duke prodhuar parashikime më të besueshme për politikën e arsimit.

Hipoteza e dytë u konfirmua përmes dy rasteve arsimore të përzgjedhura. Modeli hibrid arriti të kapë më mirë luhajtjet e papritura në rezultatet e maturës, të cilat shpesh nuk janë të ndërlidhura në mënyrë lineare me vitet e mëparshme. Po ashtu, për matjen e motivimit të stafit akademik, i cili përfshin të dhëna të natyrës subjektive dhe shpesh jo të qëndrueshme, modeli hibrid tregoi aftësi superiore për të identifikuar trajektoren e motivimit dhe për të prodhuar parashikime të besueshme që mund të ndihmojnë institucionet në menaxhimin më të mirë të burimeve njerëzore dhe përmirësimin e klimës institucionale.

Analiza e Pyetjes 2 dhe Hipotezës Përkatëse

Analizë e rasteve përkatëse dhe verifikim i hipotezës:

1) Rezultatet e maturës shtetërore:

Ky rast përfaqëson një burim të rëndësishëm të të dhënave arsimore që reflekton në mënyrë të qartë performancën kombëtare të nxënësve të arsimit parauniversitar. Seritë kohore të rezultateve të maturës në lëndë si matematika dhe gjuha shqipe përmbajnë elementë të konsiderueshëm kompleksiteti për shkak të ndikimit të faktorëve të ndryshëm si ndryshimet në strukturën e testimit, reformave arsimore, përgatitjes së mësuesve dhe ndryshimeve socio-ekonomike. Modelet klasike si ARIMA janë në gjendje të identifikojnë trendet afatgjata dhe ndryshimet sezonale në ecurinë e notave, duke dhënë një pasqyrë të qëndrueshme, por të kufizuar në rastet kur ndodhin ndryshime të papritura.

Nga ana tjetër, modeli ANN është treguar më i ndjeshëm ndaj fluktuacioneve të papritura dhe ka arritur të përshkruajë më mirë variacionet e ndikuara nga faktorë jolinearë, si për shembull, ndikimi i pandemisë COVID-19 në performancën e nxënësve apo ndryshimet në modalitetin e mësimit. Megjithatë, modeli ANN kishte vështirësi në mbajtjen e strukturës së qëndrueshme të parashikimeve për shkak të mungesës së modelimit të komponentëve trendorë.

Modeli hibrid ARIMA-ANN ka qenë në gjendje të ndërthurë forcën e të dy qasjeve. Ai ka përdorur ARIMA-n për të kapur komponentët linearë dhe të strukturuar të të dhënave, ndërsa ANN për të interpretuar variacionet jolineare që ndodhin nga viti në vit. Rezultatet e marra kanë treguar se ky model ka dhënë parashikimet më të sakta, me vlera më të ulëta të RMSE dhe MAE dhe me aftësi më të madhe për të detektuar devijimet jo të zakonshme. Ky fakt ka rëndësi të veçantë për politikën arsimore, pasi mundëson projeksione të besueshme për performancën e maturantëve dhe ndihmon në hartimin e strategjive për përmirësimin e cilësisë në arsim.

2) Motivimi i lektorëve në fakultetet e inxhinierisë:

Ky rast fokusohet në një aspekt më të sofistikuar të të dhënave arsimore – perceptimin dhe ndjenjën e motivimit të stafit akademik. Të dhënat janë mbledhur përmes një sondazhi empirik dhe janë strukturuar si seri kohore mujore. Ky lloj informacioni është nga natyra subjektiv, me ndikim të lartë nga faktorë si klima institucionale, ngarkesa akademike, zhvillimet në karrierë dhe përfitimet financiare.

Modeli ARIMA, për shkak të kufizimit të tij në interpretimin e fenomeneve jolineare, nuk ka pasur performancë të lartë në këtë rast. Ai ka qenë i dobishëm për të treguar tendenca të përgjithshme, por jo për të kuptuar luhatjet emocionale ose psikologjike që ndodhin në mënyrë të papritur. ANN, përkundrazi, ka dhënë një pasqyrë më të mirë të reagimeve të stafit ndaj ndryshimeve afatshkurtra – si për shembull, politika të reja motivuese, trajnime profesionale, ose ngarkesë mësimore në periudha specifike të vitit akademik.

Modeli hibrid ka sjellë një rezultat të balancuar: përmes komponentëve të tij linearë ka ndihmuar në evidentimin e një trendi të përgjithshëm të motivimit (p.sh., rënie graduale ose ngritje e vazhdueshme gjatë viteve), ndërsa përmes komponentëve jolinearë ka përshkruar me saktësi ndryshimet e papritura në ndjenjat e stafit. Ky model është shumë i rëndësishëm për drejtuesit e institucioneve arsimore, pasi mundëson vlerësimin e ndikimit të vendimeve administrative mbi motivimin dhe ofron një instrument të vlefshëm për menaxhimin dhe zhvillimin e burimeve njerëzore në universitete.

Përfundim për Pyetjen 2:

Nga analiza e dy rasteve arsimore rezultojnë qartë që hipoteza e dytë është e mbështetur nga të dhënat dhe rezultatet e marra nga eksperimentimi i modeleve. Modeli hibrid ARIMA-ANN jo vetëm që ka rritur saktësinë e parashikimeve, por gjithashtu ka ofruar interpretime më të thella dhe të besueshme të sjelljeve komplekse në të dhënat arsimore. Si për rezultatet e maturës, ashtu edhe për perceptimin e motivimit të lektorëve, modeli i zhvilluar ka ofruar një mjet me vlerë për analizë të thelluar, me potencial për ndikim real në përmirësimin e politikave arsimore, në përshtatjen e programeve të trajnimit dhe në ngritjen e cilësisë së shërbimeve akademike në Shqipëri.

Analiza e Pyetjes 3 dhe Hipotezës Përkatëse

Pyetja 3: Cilat janë përfitimet praktike që sjell modeli i zhvilluar për hartuesit e politikave fiskale dhe monetare, veçanërisht në parashikimin e indikatorëve të stabilitetit makroekonomik?

Hipoteza 3: Modeli i zhvilluar ARIMA-ANN mund të përdoret si një mjet mbështetës për parashikime strategjike afatshkurtra dhe afatgjata, duke kontribuar në përmirësimin e planeve të politikës ekonomike dhe menaxhimit të tregjeve në Shqipëri.

Hipoteza e tretë, e cila lidhet me përdorimin strategjik të modelit hibrid në ndihmë të vendimmarrjes ekonomike dhe monetare, u vërtetua nga rezultatet e analizës së kursit të këmbimit dhe çmimit të Bitcoin-it. Në të dyja rastet, qasja hibride ofroi parashikime më të sakta në afat të shkurtër dhe të mesëm, duke krijuar mundësi më të mëdha për reagim të hershëm nga ana e politikëbërësve. Për shembull, në menaxhimin e kursit të këmbimit, një model i tillë mund të kontribuojë në përmirësimin e politikave të ndërhyrjes së Bankës së Shqipërisë, ndërsa në tregun e kriptomonedhave ndihmon në vlerësimin e risqeve dhe mundësive për investitorët institucionalë dhe individualë.

Analizë e rasteve përkatëse dhe verifikim i hipotezës:

1. Rasti i kursit të këmbimit Euro/Lek

Ky rast përfaqëson një nga elementët më kritikë të stabilitetit makroekonomik në Shqipëri. Luhatjet në kursin e këmbimit kanë ndikim të drejtpërdrejtë në politikat fiskale dhe monetare, në konkurrueshmërinë e eksporteve dhe në fuqinë blerëse të

konsumatorëve. Analiza e kësaj serie kohore përmes modelit ARIMA tregoi se ndonëse ky model arrin të pasqyrojë trendin dhe sezonalitetin, ai nuk ka aftësi të mjaftueshme për të parashikuar lëvizjet e papritura të tregut, të cilat janë shumë të rëndësishme për ndërhyrje të hershme dhe të targetuar nga ana e institucioneve financiare.

Në të kundërt, rrjetet neuronale (ANN) kanë kapur më mirë këto luhajtje të paparashikueshme, por me kufizime në ruajtjen e strukturës lineare të serisë. Pikërisht në këtë pikë, modeli hibrid ARIMA-ANN ka arritur një ekuilibër optimal, duke kombinuar avantazhet e të dy modeleve dhe duke gjeneruar parashikime të sakta në afat të shkurtër dhe të mesëm. Këto parashikime janë thelbësore për Bankën e Shqipërisë dhe Ministrinë e Financave, pasi i ndihmojnë në planifikimin e ndërhyrjeve në tregun valutor, në vlerësimin e nevojës për ndryshime në normat e interesit, si dhe në parashikimin e ndikimit të faktorëve të jashtëm (si inflacioni në Eurozonë apo krizat gjeopolitike) mbi stabilitetin monetar të vendit. Në këtë mënyrë, modeli mund të shërbejë si një komponent i vlefshëm në kuadrin e politikëbërjes proaktive dhe të bazuar në të dhëna.

2. Rasti i çmimit të Bitcoin-it

Ky rast ofron një qasje të re në kuptimin e tregjeve alternative financiare dhe ndërlidhjes së tyre me politikën monetare dhe fiskale. Edhe pse kriptomonedhat nuk përbëjnë ende një kanal tradicional të sistemit monetar në Shqipëri, ndikimi i tyre është në rritje, veçanërisht mes të rinjve dhe investitorëve të pavarur. Çmimi i Bitcoin karakterizohet nga volatilitet ekstrem dhe sjellje thellësisht jolineare, gjë që e bën të vështirë parashikimin përmes modeleve tradicionale si ARIMA.

Në këtë rast, përdorimi i rrjeteve neuronale ka sjellë një përmirësim të konsiderueshëm në kapjen e tendencave të paparashikueshme të tregut, ndërsa ndërthurja e tyre me komponentët e ARIMA-s në modelin hibrid ka prodhuar parashikime më të besueshme për afatin e afërt. Këto rezultate mund të jenë të rëndësishme për autoritetet rregullatore, për shembull për Këshillin Mbikëqyrës të Bankës së Shqipërisë dhe për institucione të tjera financiare që kërkojnë të vlerësojnë rreziqet e përhapjes së investimeve në asete digjitale pa kontroll të mirëfilltë.

Për më tepër, ky model mund të ndihmojë edhe në ngritjen e një kuadri më të saktë për edukimin financiar dhe rregullimin e tregjeve digjitale, duke kontribuar në reduktimin e rrezikut për konsumatorët dhe stabilitetin e përgjithshëm financiar.

Përfundim për Pyetjen 3:

Bazuar në analizën e dy rasteve që përfaqësojnë komponentët kyç të stabilitetit makroekonomik – kursi i këmbimit dhe çmimi i aseteve alternative – rezulton se hipoteza e tretë është vërtetuar qartë përmes performancës së modelit hibrid. Ky model jo vetëm që përmirëson ndjeshëm saktësinë e parashikimeve, por gjithashtu ndihmon politikëbërësit të reagojnë në kohë ndaj ndryshimeve të tregut, duke e bërë atë një

instrument me vlerë për planifikimin strategjik ekonomik. Potenciali i tij për t'u integruar në sistemet ekzistuese të monitorimit dhe analizës e bën atë të aplikueshëm në mënyrë praktike për një gamë të gjerë aktorësh institucionalë dhe financiarë në Shqipëri.

7.1.3 KUFIZIME NË TRANSFERUESHMËRINË EKONOMIKE TË MODELEVE DHE VLERËSIMI KOSTO-PËRFITIM I PËRDORIMIT TË ANN

Megjithëse modelet parashikuese të përdorura në këtë studim kanë treguar performancë të lartë në rastet empirike të analizuara, transferueshmëria e tyre ekonomike në kontekste të tjera institucionale apo sektoriale mbetet e kushtëzuar. Modelet hibride si ARIMA-ANN janë ndërtuar mbi karakteristika specifike të të dhënave historike, strukturën e treguesve dhe kontekstin ekonomik ku ato aplikohen, çka nënkupton se rezultatet nuk mund të përgjithësohen automatikisht pa përshtatje metodologjike dhe validim të mëtejshëm. Nga perspektiva ekonomike dhe institucionale, përdorimi i rrjeteve neurale artificiale shoqërohet gjithashtu me kosto të konsiderueshme teknologjike dhe organizative, duke përfshirë investime në infrastrukturë informatike, sisteme për menaxhimin e të dhënave dhe kapacitete llogaritëse, si dhe nevojën për staf të specializuar me njohuri në analizë të avancuar të të dhënave dhe inteligjencë artificiale. Megjithatë, këto kosto fillestare duhet të vlerësohen në raport me përfitimet afatgjata që modelet parashikuese mund të ofrojnë, si përmirësimi i cilësisë së vendimmarrjes, reduktimi i pasigurisë ekonomike, optimizimi i burimeve dhe rritja e eficiencës institucionale. Në këtë kuadër, analiza kosto-përfitim sugjeron se përdorimi i ANN dhe modeleve hibride është më i justifikuar në institucione që operojnë me horizonte planifikimi afatmesëm dhe afatgjatë, ku përfitimet strategjike dhe institucionale tejkalojnë kostot operative afatshkurtra, duke e bërë modelimin inteligjent një investim dhe jo thjesht një shpenzim teknik.

7.2 REKOMANDIME PËR KËRKIME TË ARDHSHME DHE ZBATIM PRAKTIK

Në dritën e gjetjeve të këtij studimi, rekomandohet që modelet hibride të bëhen pjesë integrale e analizës së të dhënave në institucionet publike dhe private. Këto modele duhet të aplikohen gjerësisht në fushat e analizës së tregut të punës, vlerësimit të treguesve të zhvillimit të qëndrueshëm, si dhe në sistemin arsimor dhe shëndetësor. Kërkime të ardhshme mund të shtrihen në përdorimin e teknikave më të avancuara si LSTM (Long Short-Term Memory) apo kombinime të modeleve hibrid me qasje të optimizimit automatik, në mënyrë që të përmirësohet edhe më tej saktësia dhe fleksibiliteti. Po ashtu, rekomandohet bashkëpunimi ndër-institucional për ndarjen dhe standardizimin e të dhënave, duke e bërë modelin më të zbatueshëm në shkallë kombëtare.

Në bazë të rezultateve të arritura nga studimi dhe nga analiza e detajuar e modelit hibrid ARIMA-ANN në katër raste konkrete që përfaqësojnë fusha kyçe të zhvillimit ekonomik dhe social në Shqipëri, jepen rekomandime të ndara sipas secilit rast të

studimit. Rekomandimet janë formuluar si udhëzime praktike për institucionet përkatëse, si dhe si sugjerime për orientimin e kërkimeve të ardhshme në drejtim të përmirësimit të teknikave të parashikimit dhe zbatimit të tyre në politikëbërje dhe vendimmarrje.

7.2.1 KURSI I KËMBIMIT EURO/LEK

Kursi i këmbimit zyrtar Euro/Lek përbën një nga indikatorët më kritikë për stabilitetin ekonomik dhe funksionimin e politikës monetare në Shqipëri. Fluktuacionet e tij ndikojnë drejtpërdrejt në kostot e importit dhe eksportit, në balancat tregtare, në çmimet e mallrave dhe shërbimeve, si dhe në vendimmarrjen financiare të individëve dhe institucioneve. Kjo e bën domosdoshmërisht të nevojshëm aplikimin e metodave të avancuara për parashikimin e sjelljes së tij.

Në këtë kontekst, rekomandohet fuqimisht që modeli hibrid ARIMA-ANN të integrohet në sistemet ekzistuese të analizës dhe monitorimit të Bankës së Shqipërisë dhe institucioneve të tjera financiare. Ky model kombinon fuqinë e analizës statistikore tradicionale të ARIMA-s me fleksibilitetin dhe aftësinë e rrjeteve neuronale për të kapur modele jolineare të dhënash, duke siguruar parashikime më të sakta dhe më të qëndrueshme. Kjo qasje është veçanërisht e dobishme për të kapur luhatjet afatshkurtra të kursit, të cilat shpesh i shpëtojnë modeleve lineare për shkak të ndikimit të faktorëve psikologjikë, ndërkombëtarë, dhe spekulativë.

Zbatimi i këtij modeli do të kontribuonte në:

- *Rritja e saktësisë së parashikimeve të përditshme dhe javore të kursit të këmbimit, dhe ndikimi në reagimin e politikës monetare*

Përdorimi i modelit hibrid ARIMA-ANN në parashikimin e kursit të këmbimit Euro/Lek ofron një avantazh të ndjeshëm në identifikimin e tendencave të reja dhe luhatjeve të papritura në tregun valutor. Në mënyrë të veçantë, rritja e saktësisë në parashikimet ditore dhe javore krijon një dritare të vlefshme kohore për institucionet financiare – në radhë të parë për Bankën e Shqipërisë – për të ndërmarrë masa parandaluese ose korrigjuese. Kjo saktësi është jetike në kontekste ku një ndryshim i papritur i kursit të këmbimit mund të ndikojë direkt në çmimet e mallrave të importuara, në stabilitetin e inflacionit, në balancën e pagesave dhe në besimin e përgjithshëm të tregut.

Modelet tradicionale lineare si ARIMA mund të japin sinjale të përgjithshme mbi tendencat e kursit, por ato shpesh dështojnë në kapjen e devijimeve të menjëhershme dhe të paparashikueshme që ndodhin për shkak të ngjarjeve politike, tensioneve tregtare ose krizave financiare ndërkombëtare. Nga ana tjetër, modelet vetëm me rrjete neuronale (ANN) janë të ndjeshme ndaj variacioneve, por mund të mos jenë të mjaftueshme për të interpretuar struktura sezonaliteti ose autoregresive të të dhënave

historike. Kombinimi i të dyjave në një model hibrid kap më mirë si dimensionet afatshkurtra ashtu edhe ato afatgjata të sjelljes së kursit.

Në aspektin praktik, kjo përmirëson në mënyrë domethënëse aftësinë e Banka e Shqipërisë për të ndërhyrë në tregjet valutore me një bazë më të fortë analitike. Nëse parashikimet tregojnë një rënie të shpejtë të vlerës së Lekut kundrejt Euros, banka mund të ndërhyjë me instrumente si injektimi ose tërheqja e valutës nga tregu, rishikimi i normës bazë të interesit, apo marrja e masave të tjera të kontrollit monetar. Në të kundërt, në rast të një mbiçmimi të papritur të Lekut, ndërhyrja në kohë mund të ndihmojë në ruajtjen e konkurrueshmërisë së eksporteve shqiptare dhe në parandalimin e inflacionit të importuar negativ.

Një model i tillë mund të integrohet në sistemet ekzistuese të analizës makroekonomike dhe të përdoret për të testuar efikasitetin e ndërhyrjeve të ndryshme të politikës monetare në kohë reale. Ai gjithashtu krijon një transparencë më të madhe në komunikimin me aktorët e tregut dhe me publikun, duke forcuar besimin në vendimmarrjen e bazuar në të dhëna dhe në qëndrueshmëri analitike.

Në përfundim, përmirësimi i parashikimeve të përditshme dhe javore përmes modelit hibrid ARIMA-ANN nuk është vetëm një përfitim teknik, por përkthehet në një avantazh strategjik për politikëbërjen monetare, duke i dhënë institucionit kryesor financiar të vendit një mjet të fuqishëm për të garantuar stabilitetin ekonomik dhe për të përmbushur objektivat e saj ligjore dhe ekonomike.

- *Ndërtimi i skenarëve të simulimit dhe analiza e ndjeshmërisë për ndërhyrje të informuara në politikën monetare*

Një nga potencialet më të mëdha të modelit hibrid ARIMA-ANN në kontekstin e kursit të këmbimit Euro/Lek është aftësia e tij për të ndërtuar skenarë të simulimit që shërbejnë si bazë për analiza të ndjeshmërisë në vendimmarrje. Këto skenarë mund të përdoren nga Banka e Shqipërisë, Ministria e Financave dhe agjenci të tjera ekonomike për të parashikuar dhe kuptuar në mënyrë të strukturuar se si ndryshimet e jashtme – të cilat janë shpesh të papritura dhe të ndërlikshme me zhvillimet globale – ndikojnë mbi sjelljen e kursit të këmbimit vendas.

Për shembull, në rastet kur ndodhin kriza ndërkombëtare si rritja e çmimeve të energjisë, konflikte gjeopolitike ose tronditje financiare globale (si kolapsi i një banke të madhe në tregjet ndërkombëtare), kursi i këmbimit i vendeve të vogla dhe të ndjeshme si Shqipëria mund të pësojë luhatje të konsiderueshme. Në mungesë të një modeli të sofistikuar, analizat mbështeten shpesh në intuitë, në të dhëna të kaluara të pjesshme, ose në modele që nuk marrin parasysh kompleksitetin e ndërveprimeve ndërkombëtare. Në këtë pikë, modeli ARIMA-ANN ofron një qasje të fuqishme, pasi ndërthur njohuritë historike dhe karakteristikat statistikore të serisë me elasticitetin që sjell rrjeti neural për të modeluar ndikime të reja dhe jo-lineare.

Përmes këtij modeli, është e mundur të ndërtohen skenarë të ndryshëm të simulimit: për shembull, çfarë ndodh me kursin Euro/Lek nëse Banka Qendrore Evropiane ndryshon normën e interesit me 0.5%, ose si do të reflektohet një rënie e vazhdueshme e remitanca në 3 muajt e ardhshëm në kursin e këmbimit. Duke aplikuar këto skenarë në një ambient të kontrolluar analitik, vendimmarrësit mund të testojnë reagimet më të mundshme të tregut dhe të përcaktojnë paraprakisht llojet e politikave që duhet të ndërmerren për të amortizuar efektet negative.

Kjo qasje është veçanërisht e rëndësishme për analizat e ndjeshmërisë, të cilat ndihmojnë në kuptimin e shkallës së ndikimit që ka çdo faktor mbi kursin e këmbimit. Për shembull, përmes simulimeve, mund të vlerësohet se një luhatje në tregjet e borxhit publik ndërkombëtar mund të ketë më shumë ndikim në stabilitetin e Lekut sesa një ndryshim modest në flukset tregtare. Ky informacion është jetik për të përgatitur plane kontingjence dhe për të siguruar që politikatat e ndërhyrjes të jenë të bazuara në të dhëna dhe analiza të sakta.

Për më tepër, ndërtimi i skenarëve të tillë nxit një kulturë vendimmarrjeje të bazuar në modelim dhe projeksion brenda institucioneve publike, duke rritur transparencën dhe profesionalizmin e tyre. Ai gjithashtu mund të shërbejë për edukimin financiar të aktorëve të tregut, duke krijuar një sistem komunikimi ku Banka e Shqipërisë mund të publikojë parashikime ose analiza të ndjeshmërisë për të menaxhuar më mirë pritshmëritë e tregut dhe për të rritur besimin në politikatat monetare.

Në përfundim, modelet e simulimit të ndërtuara mbi bazën e qasjes ARIMA-ANN nuk janë vetëm mjete teknike, por kthehen në instrumente strategjike për menaxhimin proaktiv të kursit të këmbimit dhe për forcimin e qëndrueshmërisë ekonomike të vendit në një mjedis të pasigurt global.

- *Përmirësimi i transparencës dhe besueshmërisë së komunikimit publik përmes modeleve të sofistikuar parashikuese*

Një ndër përfitimet më të rëndësishme të zbatimit të modelit hibrid ARIMA-ANN në parashikimin e kursit të këmbimit është rritja e transparencës dhe besueshmërisë së komunikimit institucional në publik. Në një kontekst ku tregjet financiare, bizneset, investitorët dhe qytetarët janë gjithnjë e më të ndjeshëm ndaj sinjaleve që vijnë nga Banka e Shqipërisë dhe institucionet ekonomike, përdorimi i modeleve të avancuara dhe shkencërisht të validuara luan një rol kyç në forcimin e kredibilitetit të vendimeve dhe deklaratave publike.

Parashikimet që burojnë nga një qasje e kombinuar – që përfshin modelimin e komponentëve linearë (përmes ARIMA) dhe jolinearë (përmes ANN) – janë më të besueshme, pasi ato reflektojnë kompleksitetin real të tregut. Kjo bën që deklaratat zyrtare mbi pritshmëritë për ecurinë e kursit të këmbimit të mos duken si supozime të përgjithshme apo projeksione të bazuara vetëm në përvojën institucionale, por si

produkt i analizës së thelluar dhe të verifikuar të të dhënave historike dhe tendencave të tregut. Një komunikim i tillë përforcon besimin e publikut në institucionet financiare dhe redukton pasigurinë që shpesh i shoqëron ndërhyrjet monetare.

Për sektorin privat, veçanërisht për bizneset importuese dhe eksportuese që varen nga stabiliteti i kursit të këmbimit, një informacion i qartë dhe i bazuar në modele të testuara u mundëson atyre të planifikojnë më mirë strategjitë e tyre financiare dhe të menaxhojnë më me efikasitet rreziqet e jashtme. Investitorët – qofshin vendas apo ndërkombëtarë – janë gjithashtu më të prirur të marrin vendime investimi në një ambient ku informacioni ekonomik është i strukturuar, i parashikueshëm dhe i mbështetur në metoda shkencore të nivelit të avancuar.

Një përfitim tjetër thelbësor është rritja e legjitimitetit ndërkombëtar të institucioneve shqiptare. Kur politika monetare komunikohet përmes rezultateve të modeleve të njohura në literaturën ndërkombëtare dhe të ndërtuara mbi baza statistikore solide, partnerët ekonomikë ndërkombëtarë, organizatat financiare globale dhe agjencitë e vlerësimit të riskut kanë më shumë besim në stabilitetin makroekonomik të vendit. Kjo përkthehet në rritje të besueshmërisë për tërheqjen e fondeve të huaja, për uljen e kostove të huamarrjes dhe për përmirësimin e imazhit financiar të Shqipërisë në tregjet globale.

Në këtë mënyrë, modeli ARIMA-ANN nuk është vetëm një mjet teknik parashikimi, por edhe një instrument strategjik komunikimi, që rrit besueshmërinë, përmirëson transparencën dhe forcon marrëdhënien e institucioneve publike me aktorët e tregut. Në kushtet e globalizimit dhe të rritjes së pasigurisë ekonomike, një komunikim i tillë i bazuar në shkencë është jetik për qëndrueshmërinë ekonomike dhe për ndërtimin e një klime pozitive për zhvillimin e qëndrueshëm.

- *Optimizimi i politikave fiskale dhe monetare përmes modelit hibrid ARIMA-ANN*

Zbatimi i modelit hibrid ARIMA-ANN në parashikimin e kursit të këmbimit ka potencialin të ndikojë drejtpërdrejt në optimizimin e politikave fiskale dhe monetare në Shqipëri. Një nga përfitimet kryesore të këtij modeli qëndron në aftësinë për të gjeneruar parashikime më të sakta dhe më të qëndrueshme për luhatjet e valutës, duke ndihmuar institucionet publike të marrin vendime të bazuara në evidenca për çështje kyçe të menaxhimit ekonomik.

Së pari, përdorimi i një modeli hibrid ndihmon në përcaktimin më të saktë të normave të interesit, të cilat janë thelbësore për balancimin e inflacionit dhe stimulimin ekonomik. Një model që jep sinjale të qarta mbi ecurinë e pritshme të kursit të këmbimit mund të sinjalizojë nevojën për shtrengim apo lehtësim të politikës monetare, duke ndihmuar Bankën e Shqipërisë në përcaktimin e një kursi të politikës së saj ndërhyrëse që i përgjigjet në mënyrë dinamike kushteve reale të tregut.

Së dyti, në aspektin e buxhetimit të borxhit publik në valutë, parashikimet e sakta të kursit të këmbimit janë thelbësore për vlerësimin afatgjatë të kostos reale të borxhit të jashtëm dhe për planifikimin strategjik të strukturës së tij. Një model i tillë mund të ndihmojë Ministrinë e Financave në minimizimin e rreziqeve që burojnë nga luhatjet valutore, përmes skenarëve të besueshëm mbi ecurinë e Euro-s apo monedhave të tjera kryesore ndaj Lekut, duke mundësuar kështu mbrojtje më efikase ndaj ekspozimit financiar të shtetit.

Së treti, një tjetër fushë ku modeli gjen zbatim të drejtpërdrejtë është menaxhimi i rezervave valutore. Banka e Shqipërisë, në përpjekjet e saj për të ruajtur stabilitetin financiar dhe për të menaxhuar pasuritë në valutë të vendit, përfiton ndjeshëm nga një sistem parashikimi që ofron sinjale të besueshme për tendencat afatshkurtra dhe afatmesme të tregut. Modeli ARIMA-ANN, duke kapur si komponentët linearë të prirjes ashtu edhe variacionet jolineare të paparashikueshme, ndihmon në optimizimin e vendimeve për blerje, shitje ose mbajtje të rezervave valutore, duke siguruar qëndrueshmëri më të lartë të bilancit të pagesave dhe të politikës së kursit të këmbimit.

Në një kontekst më të gjerë, implementimi i këtij modeli si pjesë e infrastrukturës analitike të institucioneve ekonomike publike jo vetëm që ndihmon në uljen e rrezikut ekonomik makro, por gjithashtu kontribuon në përmirësimin e koordinimit ndër-institucional, duke ofruar një gjuhë të përbashkët vlerësimi për aktorët e politikëbërjes. Ai mund të shërbejë gjithashtu si një platformë e vlefshme për edukimin financiar dhe ndërtimin e kapaciteteve teknike të administratës publike në përdorimin e inteligjencës artificiale për qëllime strategjike.

Në përfundim, modeli hibrid ARIMA-ANN nuk duhet parë vetëm si një instrument teknik i analizës së serive kohore, por si një mjet inteligjent për vendimmarrje të avancuar, që forcon bazat shkencore të politikave fiskale dhe monetare në Shqipëri dhe hap rrugën për një qasje më të sofistikuar dhe proaktive në menaxhimin makroekonomik.

Për kërkime të ardhshme, rekomandohet që ky model të:

- *Zgjerimi i modelit për përfshirjen e variablave shtesë në një qasje multivariate*

Për kërkime të ardhshme, rekomandohet fuqimisht që modeli hibrid ARIMA-ANN të zgjerohet në një strukturë multivariate, duke përfshirë variabla shtesë që ndikojnë drejtpërdrejt apo tërthorazi mbi kursin e këmbimit Euro/Lek. Aktualisht, modeli i përdorur në këtë studim është i bazuar në një seri të vetme kohore (univariate), që megjithëse jep parashikime të sakta, nuk mund të kapë në mënyrë të plotë ndërveprimet e ndërlikuara të faktorëve makroekonomikë që ndikojnë mbi tregun valutë.

Në këtë drejtim, sugjerohet integrimi i variablave si normat e interesit të bonove të thesarit, të cilat reflektojnë perceptimin e tregut mbi stabilitetin fiskal dhe janë një

instrument i drejtpërdrejtë i politikës monetare. Përfshirja e tyre në model mund të ndihmojë në zbërthimin e lidhjes midis politikës së borxhit publik dhe presioneve mbi valutën kombëtare.

Gjithashtu, norma e inflacionit përbën një tregues thelbësor për vlerësimin real të fuqisë blerëse të Lekut në raport me monedhat e huaja. Një model që analizon bashkëveprimin midis inflacionit dhe kursit të këmbimit mund të ndihmojë politikëbërësit të dallojnë nëse presionet mbi valutën vijnë nga faktorë të brendshëm strukturalë apo nga tronditje të jashtme.

Një tjetër komponent me ndikim të veçantë është volumi i dërgesave monetare nga emigrantët (remittancat), të cilat përbëjnë një burim të rëndësishëm të hyrjeve valutore në Shqipëri. Variacionet sezonale dhe ciklike të remittancave mund të ndikojnë ndjeshëm mbi ofertën valutore në treg, duke ndikuar në forcimin apo dobësimin e Lekut në periudha të caktuara të vitit.

Duke ndërtuar një model hibrid multivariat, i cili kombinon aftësinë për të trajtuar marrëdhënie të ndërlikuara mes disa indikatorëve, studiuesit dhe institucionet financiare do të mund të zhvillojnë parashikime më të pasura, më interpretuese dhe më afër realitetit kompleks ekonomik. Një model i tillë do të ishte veçanërisht i vlefshëm për skenarizim politikash dhe për analizë të ndjeshmërisë ndaj tronditjeve të ndryshme të brendshme dhe të jashtme.

Në përfundim, ky zgjerim përfaqëson një hap të natyrshëm dhe të domosdoshëm në evolucionin e modeleve parashikuese për kursin e këmbimit, duke i dhënë modelit ARIMA-ANN një dimension të ri të dobishëm për vendimmarrjen makroekonomike.

- *Krahasimi i modelit hibrid me teknika të avancuara të inteligjencës artificiale si LSTM dhe GRU*

Për të matur në mënyrë më të plotë fleksibilitetin, adaptueshmërinë dhe kapacitetin parashikues të modelit të zhvilluar ARIMA-ANN, rekomandohet që në kërkime të ardhshme ky model të krahasohet me teknika më të avancuara të inteligjencës artificiale, si modelet LSTM (Long Short-Term Memory) dhe GRU (Gated Recurrent Unit). Të dyja këto teknika përfaqësojnë forma të avancuara të rrjeteve neurale rekursive (RNN), të dizajnuara në mënyrë specifike për trajtimin e serive kohore që karakterizohen nga ndërvarësi afatgjatë, sjellje jolineare të ndërlikuara, si dhe komponentë ciklikë dhe sezonalë që nuk kapen lehtësisht nga modelet tradicionale.

Modeli LSTM ka kapacitetin të ruajë informacionin e kaluar në memorien e tij të brendshme dhe të vendosë cilat pjesë të informacionit janë të rëndësishme për t'u mbajtur ose harruar në procesin e parashikimit. Kjo e bën atë jashtëzakonisht të përshtatshëm për skenarë ku ngjarje të shkuara kanë ndikim të vonuar në zhvillimet e

ardhshme një karakteristikë e zakonshme në tregjet financiare, si p.sh. kursi i këmbimit apo çmimi i Bitcoin-it.

Nga ana tjetër, modeli GRU, megjithëse më i thjeshtë se LSTM në strukturë, është më efikas në aspektin e konsumit të burimeve kompjuterike dhe shpeshherë jep rezultate të krahasueshme me LSTM për seri kohore komplekse. Krahasimi i modelit ARIMA-ANN me këto dy teknika do të mundësonte një vlerësim më të thelluar të përfitimeve relative, duke analizuar jo vetëm saktësinë e parashikimit (RMSE, MAE, MAPE), por edhe kostot e trajnimit, adaptueshmërinë ndaj të dhënave të reja, si dhe qëndrueshmërinë në parashikime afatgjata.

Zbatimi i këtij krahasimi do të kontribuonte ndjeshëm në avancimin e kërkimeve në fushën e parashikimit të serive kohore në Shqipëri, duke orientuar përdoruesit institucionalë dhe studiuesit drejt përdorimit të metodologjive më efektive për sfidat konkrete që përballen në tregjet ekonomike dhe financiare. Për më tepër, kjo qasje krahasuese do të shërbente si bazë për ndërtimin e metamodeleve optimizuese, që mund të kombinojnë më tej pikat e forta të modeleve ekzistuese për të arritur performancë të lartë në mjedise të ndryshme të të dhënave.

- *Zbatimi i modelit në analiza afatgjata për vlerësimin e prirjeve strukturore të kursit të këmbimit*

Një tjetër drejtim i rëndësishëm për kërkime të ardhshme është zgjerimi i përdorimit të modelit hibrid ARIMA-ANN për analiza afatgjata të kursit të këmbimit, me fokus në prirjet strukturore që formësojnë zhvillimin ekonomik në nivel kombëtar dhe ndërkombëtar. Në këtë kontekst, nuk mjafton vetëm parashikimi i luhatjeve ditore apo javore të kursit, por kërkohet të vlerësohen tendencat e thella dhe të qëndrueshme që burojnë nga faktorë si ndryshimet demografike (rritja ose tkurrja e popullsisë aktive), zhvillimet teknologjike (digjitalizimi i sistemit financiar, përhapja e kriptomonedhave, automatizimi i tregjeve), si dhe dinamika ekonomike globale (ndryshimet në bilancet tregtare, politikat fiskale dhe monetare në eurozonë apo SHBA, ndikimi i luftërave tregtare apo krizave energjetike).

Përfshirja e këtyre komponentëve në një kornizë afatgjatë të modelimit do ta rrisë kapacitetin e modelit për të sugjeruar skenarë zhvillimi të bazuar në supozime të ndryshme strukturore. Kjo është veçanërisht e rëndësishme për Bankën e Shqipërisë dhe Ministrinë e Financave, të cilat mund të përdorin këtë model për të hartuar politika të qëndrueshme dhe proaktive, të bazuara në një kuptim të thelluar të faktorëve nxitës afatgjatë.

Në këtë drejtim, modeli mund të ndihmojë në identifikimin e pikave kritike të transformimit ekonomik, në vlerësimin e ndikimit të reformave strukturore, dhe në optimizimin e pozicionit monetar të vendit në raport me tregjet ndërkombëtare, duke

siguruar që Shqipëria të ruajë një kurs të qëndrueshëm dhe konkurrues në një mjedis global gjithnjë e më të ndërlikuar dhe të paparashikueshëm.

- *Integrimi i modelit me sistemet e paralajmërimit të hershëm për identifikimin e presioneve në tregjet valutore*

Rekomandohet fuqimisht që modeli hibrid ARIMA-ANN të integrohet në sistemet ekzistuese të paralajmërimit të hershëm të përdorura nga institucionet financiare, si Banka e Shqipërisë dhe Ministria e Financave, me qëllim që të identifikohen në kohë reale momentet kritike të presionit mbi tregjet valutore. Këto presione, të cilat mund të vijnë nga faktorë të brendshëm (si p.sh. rënie e papritur e rezervave valutore, deficit i thelluar tregtar, tkurrje e remitancave) apo nga faktorë të jashtëm (si krizat ndërkombëtare financiare, luhatje të forta të eurozonës, ndryshime në politikën monetare globale), përbëjnë rreziqe të mëdha për stabilitetin e kursit të këmbimit dhe inflacionin e brendshëm.

Falë aftësisë së modelit për të kapur si komponentët linearë ashtu edhe ato jolinearë, ai është i përshtatshëm për të parashikuar devijime të papritura nga sjellja normale e tregut, duke vepruar si një sensor inteligjent i treguesve të rrezikut. Nëpërmjet analizës së sinjaleve të hershme, ky model mund të përdoret për të aktivizuar mekanizma kontrolli dhe ndërhyrjeje, si rritja e normave të interesit, rebalancimi i rezervave monetare, ose fushata për të stabilizuar pritshmëritë e aktorëve të tregut.

Në këtë mënyrë, integrimi i modelit në sistemet e paralajmërimit nuk do të jetë vetëm një risi teknike, por një instrument strategjik për ruajtjen e stabilitetit makroekonomik, duke lehtësuar vendimmarrjen e shpejtë, të informuar dhe të besueshme në periudha të pasigurisë së lartë. Kjo qasje është në përputhje me praktikat më të mira të organizatave ndërkombëtare si FMN dhe Banka Botërore, të cilat theksojnë rëndësinë e modelimit të rrezikut në kohë reale si pjesë e menaxhimit makroekonomik modern.

Së fundmi, rekomandohet një bashkëpunim i ngushtë ndërinstitucional midis Bankës së Shqipërisë, Ministrisë së Financave, universiteteve dhe instituteve kërkimore, për të ndërtuar një qendër kombëtare të parashikimit makroekonomik që përdor modele hibride dhe teknologji të inteligjencës artificiale për vendimmarrje të bazuar në të dhëna dhe për politika publike më të sofistikuara dhe më efektive.

7.2.2 ÇMIMI DITOR I BITCOIN-IT

Në kushtet e një tregu financiar gjithnjë e më të ndikuar nga aktivitetet dixhitale dhe kriptomonedhat, çmimi i Bitcoin-it përfaqëson një nga indikatorët më të rëndësishëm për vlerësimin e paqëndrueshmërisë financiare dhe rreziqeve të investimit. Rezultatet e këtij studimi tregojnë se përdorimi i modelit hibrid ARIMA-ANN, i cili kombinon përpunimin linear të serive kohore me kapacitetin për të mësuar sjellje jolineare dhe dinamike të rrjeteve neuronale artificiale, ofron përfitime të rëndësishme për analizën e kësaj serie të paqëndrueshme.

Përfitimet praktike për sektorin financiar dhe atë teknologjik janë të shumta. Së pari, modeli mund të zbatohet për rritjen e saktësisë së parashikimeve afatshkurtra dhe ndërjavore, gjë që ndihmon investitorët të marrin vendime të informuara në kohë reale, duke reduktuar ekspozimin ndaj luhatjeve të papritura. Kjo është veçanërisht e rëndësishme për operatorët që përdorin strategji tregtimi algoritmik (algo-trading), të cilët varen nga sinjalet e shpejta dhe të sakta.

Së dyti, rekomandohet që institucionet financiare dhe startup-et fintech që ofrojnë shërbime mbi kriptovalutat të ndërtojnë sisteme të automatizuara të menaxhimit të rrezikut mbi bazën e këtij modeli. Duke përdorur parashikime të sofistikuar për trendet e çmimit të Bitcoin-it, këto sisteme mund të llogarisin automatikisht kufijtë e ekspozimit, të aktivizojnë strategji mbrojtëse (hedging) dhe të përcaktojnë momentin optimal për ndërhyrje.

Një tjetër rekomandim është zhvillimi i platformave të edukimit financiar mbi rreziqet e kriptomonedhave, ku modeli mund të shërbejë si një shembull ilustrues për të demonstruar kompleksitetin e parashikimit të çmimeve në këtë treg. Kjo do të ndihmonte investitorët fillestarë të kuptojnë më mirë ndërlikimet e tregut të kriptove dhe të shmangin vendimmarrjet impulsive.

Në drejtim të kërkimeve të ardhshme, sugjerohet integrimi i këtij modeli me teknika më të avancuara të inteligjencës artificiale, përfshirë algoritme të optimizimit evolucionar (si algoritmet gjenetike ose Particle Swarm Optimization) dhe rrjete neuronale të thelluara (si LSTM ose Transformer). Këto teknika mund të përmirësojnë më tej performancën e modelit në kushte të paqëndrueshme të tregut, ku dinamikat e çmimit nuk ndjekin struktura të qëndrueshme klasike.

Po ashtu, mund të zhvillohen modele multivariate, ku përveç çmimit të Bitcoin-it të përfshihen edhe variabla të tjerë të rëndësishëm si vëllimi i tregtimit, normat e interesit, sentimentu i tregut (i matur përmes analizës së tekstit në rrjete sociale), apo zhvillimet gjeopolitike, me qëllim ndërtimin e një sistemi të integruar parashikues të tregjeve të kriptove.

7.2.3 REZULTATET E MATURËS SHTETËRORE

Në kontekstin e analizës së performancës arsimore në Shqipëri, rezultatet e provimeve të maturës shtetërore përfaqësojnë një burim të vlefshëm informacioni për vlerësimin e cilësisë së sistemit parauniversitar dhe për orientimin strategjik të politikave arsimore. Ky studim konfirmoi se modeli hibrid ARIMA-ANN, për shkak të aftësisë për të kapur si komponentët linearë ashtu edhe ata jolinearë të të dhënave, ofron një mjet shumë më të saktë për parashikimin e këtyre rezultateve krahasuar me modelet tradicionale. Rekomandohet fuqimisht që ky model të integrohet në strukturat ekzistuese të analizës së të dhënave në Ministrinë e Arsimit dhe institucionet arsimore vendore.

Zbatimi praktik i këtij modeli do të mundësonte identifikimin më të hershëm dhe më të saktë të prirjeve të performancës, si në nivel të përgjithshëm kombëtar, ashtu edhe në ndarjet gjeografike, të tilla si qarqe, bashki apo shkolla specifike. Kjo analizë do të ndihmonte në ndërtimin e hartave të performancës arsimore, të cilat do të shërbenin si bazë për ndërhyrje të synuara, duke përmirësuar barazinë dhe efikasitetin e sistemit arsimor.

Një tjetër aspekt me rëndësi është përdorimi i modelit për të krahasuar performancën në lëndë kyçe si Matematika dhe Gjuha Shqipe, që janë përcaktuese për aksesin në arsimin e lartë. Nëpërmjet analizës së devijimeve të papritura ose prirjeve të qëndrueshme, institucionet mund të rishikojnë më mirë programet mësimore, trajnimet e mësuesve dhe mekanizmat e vlerësimit.

Rekomandohet gjithashtu ndërtimi i sistemeve të inteligjencës arsimore, ku modeli ARIMA-ANN mund të jetë pjesë e një platforme të gjerë që ndihmon në monitorimin e progresit, krahasimin ndërvite, dhe përcaktimin e ndikimit të reformave të reja në sistemin arsimor. Këto sisteme mund të përdoren për të ndihmuar vendimmarrësit në përcaktimin e politikave më efektive për përgatitjen e studentëve dhe për uljen e pabarazive në cilësi dhe akses në arsim.

Në drejtim të kërkimeve të ardhshme, rekomandohet zgjerimi i analizës përmes integritit të të dhënave të tjera si gjinia, statusi socio-ekonomik, vendbanimi (rural/urban), prania e klasave të veçanta për nxënës me nevoja të veçanta, apo rezultatet e viteve të mëparshme. Kjo do të mundësonte ndërtimin e modeleve multidimensionale, të cilat jo vetëm që rrisin saktësinë e parashikimit, por ofrojnë edhe skenarë rekomandues për përmirësimin e politikave arsimore në mënyrë të personalizuar sipas karakteristikave të popullatës nxënëse.

Së fundi, bashkëpunimi midis institucioneve publike (MAS, QSHA) dhe qendrave të kërkimit akademik rekomandohet si thelbësor për rritjen e cilësisë së modelimit dhe për përhapjen e kulturës së analizës së bazuar në të dhëna, që mund të nxisë edhe zhvillimin e platformave digjitale për menaxhimin e performancës arsimore në nivel kombëtar.

7.2.4 MOTIVIMI I LEKTORËVE NË FAKULTETET E INXHINIERISË

Motivimi i stafit akademik përbën një shtyllë thelbësore për sigurimin e cilësisë në arsimin e lartë, sidomos në fushat teknike si inxhinieria, ku kërkesat pedagogjike dhe kërkimore janë të larta dhe dinamike. Studimi aktual, nëpërmjet aplikimit të modelit hibrid ARIMA-ANN në seritë kohore të motivimit të lektorëve, solli një risi metodologjike në mënyrën e monitorimit dhe parashikimit të këtij treguesi delikat, duke ofruar kështu një qasje të re ndaj menaxhimit të burimeve njerëzore në universitete.

Rekomandohet që çdo fakultet i shkencave inxhinierike dhe teknike të zhvillojë sisteme të institucionalizuara të vëzhgimit periodik të nivelit të motivimit të stafit, të bazuara në pyetësorë të standardizuar dhe të administruar në mënyrë të rregullt (p.sh. çdo

semestër ose çdo vit akademik). Këto të dhëna, kur analizohen përmes modeleve hibride si ARIMA-ANN, mund të zbulojnë trende të fshehura dhe modele të përsëritura që shpesh nuk janë të dukshme përmes analizave tradicionale statistikore.

Një përfitim konkret i zbatimit të këtij modeli është mundësia për të ndërmarrë masa korigjuese në kohë, duke reaguar proaktivisht ndaj uljes së motivimit përpara se të përkthehet në pasoja konkrete si rënie të performancës mësimore, pakënaqësi në vendin e punës apo largime nga institucioni. Parashikimet afatshkurtra dhe afatmesme të tendencave të motivimit mund të ndihmojnë në planifikimin më të mirë të politikave të nxitjes, siç janë: mundësitë për zhvillim profesional, përfshirja në projekte kërkimore, shpërblyerjet financiare apo përmirësimi i kushteve të punës.

Rekomandohet gjithashtu që analiza e motivimit të lidhet ngushtë me tregues të tjerë të performancës, si numri i publikimeve shkencore, pjesëmarrja në konferenca, vlerësimet nga studentët, apo angazhimi në projekte institucionale. Një ndërthurje e tillë do të mundësonte ndërtimin e modeleve kompleksë të menaxhimit strategjik të personelit akademik, duke ndihmuar në ndarjen e burimeve sipas nevojave dhe në formulimin e strategjive të qëndrueshme për rritjen e produktivitetit akademik.

Në drejtim të kërkimeve të ardhshme, sugjerohet zgjerimi i analizës së motivimit në një kampion më të gjerë ndër-universitar, për të evidentuar dallimet sipas degëve, pozicioneve akademike, viteve të eksperiencës dhe faktorëve institucionalë. Për më tepër, integrimi i modeleve hibride me teknologji të inteligjencës artificiale të avancuar (si LSTM apo algoritmet evolutive) do të mundësonte ndërtimin e platformave digjitale për menaxhimin emocional dhe profesional të stafit akademik, duke sjellë më afër idenë e një universiteti të orientuar nga mirëqenia dhe zhvillimi i qëndrueshëm i burimeve njerëzore.

Së fundi, është e rëndësishme që bashkëpunimi midis departamenteve të personelit, njësive të sigurimit të brendshëm të cilësisë dhe njësive të kërkimit shkencor të fuqizohet, në mënyrë që të krijohet një kulturë institucionale që mbështet përdorimin e të dhënave për vendimmarrje dhe përmirësim të vazhdueshëm të mjedisit akademik.

7.2.5 REKOMANDIME TË PËRGJITHSHME PËR KËRKIME DHE ZBATIM INSTITUCIONAL

Bazuar në rezultatet e këtij studimi dhe në përvojën praktike të aplikimit të modelit hibrid ARIMA-ANN në katër fusha të rëndësishme për zhvillimin ekonomik, teknologjik dhe arsimor të Shqipërisë, formulohen disa rekomandime të përgjithshme që synojnë institucionalizimin dhe zgjerimin e përdorimit të modeleve të avancuara të parashikimit në vendimmarrje dhe kërkime të ardhshme. Rekomandohet fuqimisht që institucionet publike, si Banka e Shqipërisë, Ministria e Arsimit, Ministria e Ekonomisë, si dhe agjencitë statistikore dhe planifikuese, të integrojnë modelet hibride si pjesë të pandashme të proceseve të tyre analitike dhe strategjike. Duke qenë se këto

modele janë të afta të përpunojnë të dhëna me natyrë jolineare, të ndryshueshme dhe të paqëndrueshme, ato paraqesin një alternativë tepër efikase ndaj modeleve tradicionale statistikore, të cilat shpesh dështojnë të kapin kompleksitetin e të dhënave moderne.

Në mënyrë që kjo qasje të jetë funksionale dhe e qëndrueshme, është thelbësore të ndërtohet një infrastrukturë kombëtare për analitikën e të dhënave, e cila përfshin jo vetëm teknologjinë, por edhe politikat për mbledhjen, standardizimin, ruajtjen dhe ndarjen e të dhënave midis institucioneve. Bashkëpunimi ndërinstitucional duhet të inkurajohet përmes protokolleve të qarta të bashkëndarjes së të dhënave, projekteve të përbashkëta kërkimore dhe zhvillimit të qendrave të ekspertizës për modelim dhe analizë parashikuese. Në këtë mënyrë, do të krijohen kushtet për një ekosistem të integruar të vendimmarrjes së bazuar në evidencë, duke ndihmuar jo vetëm sektorin publik, por edhe bizneset dhe universitetet të ndërtojnë politika më të sakta dhe më proaktive.

Rekomandohet gjithashtu që këto modele kanë treguar performancë të lartë në domene të ndryshme ndërkombëtare dhe janë posaçërisht të përshtatshme për të trajtuar të dhëna me varësi të gjatë kohore, luhatshmëri ekstreme dhe karakteristika të paparashikueshme, që janë të zakonshme në tregjet financiare, indikatorët makroekonomikë dhe dinamikat arsimore e demografike.

Po ashtu, një drejtim i rëndësishëm për të ardhmen është automatizimi i procesit të përzgjedhjes së parametrave optimalë të modelit, përmes teknikave të optimizimit evolucionar, si algoritmet gjenetike apo optimizimi Bayes-ian. Këto qasje mund të kontribuojnë në ndërtimin e platformave inteligjente të vendimmarrjes që nuk kërkojnë ndërhyrje të vazhdueshme njerëzore dhe që përditësohen në mënyrë dinamike sipas të dhënave që vijnë në kohë reale.

Së fundi, sugjerohet që universitetet dhe institucionet kërkimore në Shqipëri të përfshijnë në kurrikulat e tyre trajnime specifike mbi modelet hibride, machine learning dhe inteligjencën artificiale të zbatuar në analiza kohore, për të përgatitur breza të rinj ekspertësh që do të jenë në gjendje të përdorin dhe zhvillojnë më tej këto teknologji në kontekstin shqiptar. Kjo përgatitje e burimeve njerëzore është vendimtare për të garantuar që zbatimi i këtyre rekomandimeve të mos mbetet në nivel pilot, por të kthehet në praktikë të përhapur në të gjitha nivelet e politikëbërjes dhe zhvillimit.

7.3 PËRMBYLLJE

Ky studim përfaqëson një përpjekje të thelluar kërkimore për të eksploruar dhe demonstruar vlerën e shtuar që sjell integrimi i metodave klasike statistikore me teknikat moderne të inteligjencës artificiale në analizën dhe parashikimin e serive kohore në Shqipëri. Duke ndërthurur fuqinë modeluese të modelit autoregresiv ARIMA, i cili trajton me efikasitet komponentët linearë të të dhënave, me fleksibilitetin dhe aftësinë e rrjeteve neuronale artificiale (ANN) për të kapur strukturat jolineare,

është ndërtuar një model hibrid ARIMA-ANN që synon të përmirësojë ndjeshëm cilësinë dhe saktësinë e parashikimeve në fusha të ndryshme me rëndësi kombëtare.

Gjatë këtij punimi janë trajtuar katër raste të ndryshme, por komplementare: kursi i këmbimit Euro/Lek, çmimi ditor i Bitcoin-it, rezultatet e maturës shtetërore dhe motivimi i lektorëve universitarë. Secili prej këtyre rasteve ka karakteristika specifike, të cilat kanë shërbyer për të testuar fleksibilitetin dhe adaptueshmërinë e modelit të propozuar në kontekste të ndryshme nga makroekonomia dhe tregjet financiare deri te arsimit dhe menaxhimi i burimeve njerëzore në institucionet e arsimit të lartë. Përmes këtij qasjeje ndërdisiplinore, është synuar jo vetëm ndërtimi i një modeli të qëndrueshëm parashikimi, por edhe vlerësimi i ndikimit praktik që ai mund të ketë në mbështetjen e vendimmarrjes publike dhe institucionale në Shqipëri.

Rezultatet e arritura kanë qenë domethënëse dhe plotësisht në përputhje me pritshmëritë teorike dhe praktike të formuluar në fillim të studimit. Në të gjitha rastet e analizuar, modeli hibrid ka tejkaluar performancën e modeleve të izoluara ARIMA dhe ANN në terma të treguesve të saktësisë si RMSE, MAE dhe MAPE. Veçanërisht në seri kohore me sjellje jolineare të theksuar, siç është rasti i çmimit të Bitcoin-it apo i të dhënave të motivimit të stafit akademik, përfitimi nga ndërthurja e dy qasjeve ka qenë i dukshëm.

Modeli hibrid jo vetëm që ka siguruar një përshkrim më realist të dinamikës së serive, por gjithashtu ka ofruar parashikime më të qëndrueshme dhe më të dobishme për përdorim praktik. Kjo përforcon vlerën shkencore të integritetit të metodave të ndryshme në ndërtimin e modeleve hibride që përballojnë më mirë kompleksitetin e realitetit.

Gjithashtu, nëpërmjet analizës së përmbushjes së objektivave dhe vlerësimit të hipotezave kërkimore, ky studim konfirmoi se modeli hibrid ARIMA-ANN mund të shërbejë si një instrument me rëndësi strategjike për aktorët institucionalë dhe politikëbërësit në Shqipëri. Për Bankën e Shqipërisë, ky model ofron një mjet të avancuar për parashikimin afatshkurtër dhe afatmesëm të kursit të këmbimit dhe mund të ndihmojë në formulimin e politikave monetare më të sakta dhe të orientuara drejt stabilitetit.

Në tregun e kriptomonedhave, përdorimi i këtij modeli nga investitorët dhe startup-et fintech mund të kontribuojë në përmirësimin e menaxhimit të riskut dhe vendimmarrjes së informuar në kohë reale. Në fushën e arsimit, modelet hibride mund të zbatohet nga Ministria e Arsimit për të identifikuar faktorët që ndikojnë në performancën e maturantëve dhe për të orientuar politikën arsimore në mënyrë më të targetuar. Në mënyrë të ngjashme, universitetet mund të përfitojnë nga ky model për të matur dhe përmirësuar motivimin e stafit akademik, duke ndërtuar strategji më efektive të menaxhimit njerëzor dhe të zhvillimit profesional.

Nga ana kërkimore, ky punim kontribuon në literaturën akademike si një dëshmi praktike e aplikueshmërisë së modeleve hibride në një mjedis konkret si Shqipëria. Ai ofron një strukturë metodologjike të detajuar, e cila mund të merret si model nga studiues të tjerë në fusha të ndryshme, duke përfshirë ekonominë, financat, arsimin dhe teknologjinë. Për më tepër, ai hap horizonte të reja për kërkime të ardhshme që mund të përdorin algoritme më të avancuara të mësimin të thelluar, si LSTM apo GRU, ose të testojnë integrimin e modeleve hibride me mekanizma të optimizimit automatik, duke rritur kështu performancën dhe shkallën e zbatueshmërisë së tyre në sisteme të mëdha të të dhënave (big data).

ky punim dëshmon se integrimi i metodave klasike statistikore me teknikat moderne të inteligjencës artificiale përbën një alternativë efektive dhe të besueshme për përballimin e sfidave që paraqesin seritë kohore të ndërlikuara dhe dinamike në kontekste reale. Ai përfaqëson një hap të rëndësishëm drejt ndërtimit të kapaciteteve analitike më të avancuara në Shqipëri dhe i jep një shtysë të re procesit të digjitalizimit dhe inteligjencës vendimmarrëse në nivel kombëtar.

Në këtë mënyrë, përmes një qasjeje të integruar dhe inovative, modeli hibrid ARIMA-ANN kontribuon në përmirësimin e cilësisë së analizës së të dhënave, në hartimin e politikave të bazuara në evidencë dhe në zhvillimin e qëndrueshëm të institucioneve në një epokë të udhëhequr nga të dhënat.

7.4 REFLEKTIM MBI ROLIN DHE KUFIJTË E PËRDORIMIT TË MODELEVE PARASHIKUESE

Modelet parashikuese të zhvilluara në këtë studim janë konceptuar për t'u përdorur nga aktorë institucionalë si banka qendrore, institucione publike, universitete dhe organizata që operojnë në mjedise të ndërlikuara ekonomike dhe sociale, ku nevoja për planifikim të bazuar në të dhëna është thelbësore. Qëllimi i këtyre modeleve nuk është të zëvendësojnë procesin e vendimmarrjes, por të ofrojnë informacion analitik të strukturuar që mbështet gjykimin profesional dhe strategjik të vendimmarrësve.

Modelet nuk pretendojnë të parashikojnë me siguri absolute zhvillimet e ardhshme, të eliminojnë pasigurinë apo të marrin parasysh të gjithë faktorët ekonomikë, socialë dhe institucionalë që ndikojnë në realitetin kompleks të sistemeve të studiuara. Për rrjedhojë, është thelbësore të bëhet një dallim i qartë midis parashikimit si proces sasior i bazuar në modele dhe vendimmarrjes si proces normativ dhe strategjik, i cili kërkon interpretim, kontekstualizim dhe përgjegjësi institucionale.

Në këtë kuptim, parashikimi duhet parë si një mjet ndihmës që orienton, por nuk përcakton vendimet, duke siguruar një përdorim të kujdesshëm, të përgjegjshëm dhe të qëndrueshëm të modeleve inteligjente në praktikën ekonomike dhe institucionale.

REFERENCAT

- [1] Areekul P., Senjyu, T., Toyama, H., Yona, A. (2010). "A Hybrid ARIMA and Neural Network Model for Short-Term Price Forecasting in Deregulated Market" in IEEE Transactions on Power Systems. Volume: 25, Issue: 1. pp. 524-530, doi:10.1109/tpwrs.2009.2036488.
- [2] Armstrong, J.S., (2001). Principles of Forecasting: A Handbook for Researchers and Practitioners. ISBN-10: 0792374010, ISBN-13: 978-0792374015. Springer Publisher.
- [3] Aryal, D.R., & Yao-Wu, W., (2003), Neural Network Forecasting of the production level of Chinese construction industry; Journal of Comparative International Management 6(2); 45–64.
- [4] Asteriou, D., & Hall, S.G. (2007). Applied econometrics: a modern approach. New York: Palgrave Macmillan. 397 p.
- [5] Athanassopoulos, G., Hyndman, R.J., Song, H., Wu, D.C., (2010). "The tourism forecasting competition". Department of Econometrics and Business Statistics and Tourism Research Unit, Monash University, VIC 3800, Australia.
- [6] Babu C. N., & Reddy B. E. (2014) A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data. Published in Appl. Soft Comput.
- [7] Balkin, S.D., & Ord, J.K., (2000). Automatic neural network modeling for univariate time series. International Journal of Forecasting 16 (2000) 509–515.
- [8] Bandyopadhyay, G. and Chattopadhyay S. (2006) An Artificial Neural Net approach to forecast the RPM of India.
- [10] Batista, M. (2020). Estimation of the final size of the COVID-19 epidemic. Preprint. medRxiv.
- [11] Becker, S., (1991). "Unsupervised learning procedures for neural networks,"International Journal of Neural Systems, vol. 2, 17-33.
- [12] Bojorquez, E., Bojorquez, J., Ruiz S.E., & Reyes -Salazar, A., (2012). "Prediction of inelastic response spectra using artificial neural networks", Math. Pr. in Eng., Article ID 937480, 5 pages.
- [13] Bollerslev, T., (1986) Generalized autoregressive conditional heteroskedasticity. Journal of Econometrics, University of California at San Diego, La Jolla, CA 92093, USA vol. 31, issue 3, 307-327.
- [14] Chen, K.Y., & Wang, C.H. (2007). A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. ELSEVIER Journal, Expert Systems with Applications 32 (2007), 254-264.
- [16] Clemen, R.T. (1989). Combining forecasts: A review and annotated bibliography. International Journal of Forecasting, vol. 5, issue 4, 559-583.
- [17] Cryer JD, Chan KS. (2008). Times series analysis with applications in R. Berlin, Germany:Springer.
- [18] Danielsson, J.. (1994) Stochastic volatility in asset prices estimation with simulated maximum likelihood. Journal of Econometrics, vol. 64, issue 1-2, 375-400.

- [19] Dara, F., (2014) “ Parashikimi i Sasisë së Poleneve Alergjizuese me Anën e Rrjetave Neurale”. Fakulteti i Shkencave të Natyrës. Universiteti i Tiranës.
- [20] Davis, J.J., Clark, A.J. (2011).Data preprocessing for anomaly based network intrusion detection: A review. *Computers and Security*, 30: 1–23.
- [21] Denton, J.W. (1995). How good are neural networks for causal forecasting? *Journal of Business Forecasting Methods and Systems*, 14(2), 17-21.
- [22] Dickey, D.A. & Fuller, W.A. (1979) Distribution of Estimators for Time Series Regressions with a Unit Root, *Journal of the American Statistical Association* 74, 427-43.
- [23] Dickey, D.A. & Fuller, W.A. (1981) Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root, *Econometrica* 49(4), 1057-1072
- [24] Dunis, C.L., & Huang, X., (2002) Forecasting and trading currency volatility: an application of recurrent neural regression and model combination, *Journal of Forecasting*, 21 (5), pp. 317-354. Online ISSN: 1099-131X Impact Factor: 0.747
- [25] Dunis, C.L., Laws, J. & Sermpinis, G. (2011) Higher order and recurrent neural architectures for trading the EUR/ USD exchange rate, *Quantitative Finance*, 11 (4), pp. 615-629. IF: 0.960.
- [26] Engel, C., Mark, N.C., West, K.D., (2008) “ Exchange Rate Models Are Not as Bad as You Think”. NBER Macroeconomics, Volume 22 Publisher: University of Chicago Press ISBN: 978-0-226-00202-6. p. 381 – 441.
- [27] Enke, D., Mehdiyev, N. (2022) A New Hybrid Approach For Forecasting Interest Rates. *Procedia Computer Science* 12 259 – 264 1877-0509 Organized by Missouri University of Science and Technology Washington D.C. © Published by Elsevier. doi: 10.1016/j.procs.
- [29] Fu, L., (1994). Representation of rule-based knowledge in neural networks. *Neural Networks IEEE World Congress on Computational Intelligence*. Print ISBN: 0-7803-1901-X INSPEC Accession Number: 4939925. DOI: [10.1109/ICNN.1994.374506](https://doi.org/10.1109/ICNN.1994.374506);Germany: Springer.
- [30] Gershenfeld, N.A., & Weigend, A.S., (1994). “Time Series Prediction: Forecasting the Future and Understanding the Past”, Vol. XV of Santa Fe Institute Studies in the Sciences of Complexity, Addison- Wesley, Reading, MA, pp.1–70.
- [31] Gil, D., Girela J. L., Juan J., Torres, M. J. G., Johnsson, M., (2012) Predicting seminal quality with artificial intelligence methods. ELSEVIER Ltd.
- [32] Ginzburg, I. & Horn, D. (1994). Combined neural networks for time series analysis, *Advances in Neural Information Processing Systems*, 6, 224-23.
- [33] Goh, W.Y., Lim, C.P., & Peh, K., (2003). Predicting Drug Dissolution Profiles with an Ensemble of Boosted Neural Networks: A Time Series Approach. *IEEE Transactions on Neural Networks*, Volume: 14, Issue: 2, pg. 459-463. DOI: 10.1109/TNN.2003.809420.
- [34] Greene, W. (2011) *Econometric Analysis: International Edition*. Pearson Education; 7 edition. ISBN-10: 0273753568 ISBN-13: 978-0273753568.
- [35] Grolemond, G., & Wickham, H. (2016). “ R for Data Science”. O’Reilly Publisher, First Edition. ISBN-13: 978-1491910399 ISBN-10: 1491910399.

- [36] Guo W.W., Li, M.M., Whymark, G., & Li, Z.X., (2009). “Mutual complement between statistical and neural network approaches for rockmagnetism data analysis,” *Expert Systems with Applications*, vol. 36, no. 6, pp. 9678– 9682.
- [37] Guo, W.W., Xue, H., (2014). “ Crop Yield Forecasting Using Artificial Neural Networks: A Comparison between Spatial and Temporal Models ”, Hindawi Publishing Corporation *Mathematical Problems in Engineering*, Vo lume 2014, Article ID 857865, 7 pages. ISSN, 15635147, 1024123X.
- [38] Gva ladze, S. (2015) Evaluating methods for time -series forecasting; Applied to energy consumption predictions for Hvaler (kommune). Ostfold University, Norway.
- [39] Gjika, E., (2014). “Seritë kohore, reduktimi i përmasave, parashikimi: studimi i ngjashmërive nëpërmjet reduktimit të përmasave të serisë, metoda sa x”. Fakulteti i Shkencave të Natyrës. Universiteti i Tiranës. fq. 29-33.
- [40] Gjonça, A., & Aassveand. A., & Mencarini, L., (2006) “The highest RPM in Europe - for how long? The analysis of RPM change in Albania based on individual data” University of Essex, Colchester, UK.
- [41] Hajirahimi, Z., & Khashei, M., (2016) “Improving the performance of financial forecasting using different combination architectures of ARIMA and ANN models”. *Jiems Journal of Industrial Engineering and Management Studies* Vol. 3, No. 2, pp. 17-32.
- [42] Hamilton, F., Lloyd, A.L., Flores, K.B., (2017) “ Hybrid modeling and prediction of dynamical systems”. *PLOS Comput Biol* 13(7): e1005655. [https://doi.org/10.1371/ journal.pcbi.1005655](https://doi.org/10.1371/journal.pcbi.1005655). Jeffrey J. Saucerman, University of Virginia, UNITED STATES.
- [43] Hamzacebi, C., (2008). “Improving art ificial neural networks’ performance in seasonal time series forecasting”, *Information Sciences* 178. pages: 4550 -4559.
- [44] He, G., & Deng, Q., (2012) “A Hybrid ARIMA and Neural Network Model to Forecast Particulate Matter Concentration in Changsha, China.” National Key Project of Scientific and Technical Supporting Programs of China (No. 2008BAJ12B03).
- [45] Hipel, K.W., & Mc Leod, A.I., (1994) “Time Series Modelling of Water Resources and Environmental Systems”, Amsterdam, Elsevier.
- [46] Hornik, K., Stinchcombe, M., & White, H., (1989). “Multilayer feedforward networks are universal approximators,” *Neural Networks*, vol. 2, no. 5, pp. 359– 366.
- [47] Hsieh, D.A. (1988) “The statistical properties of daily foreign e xchange rates: 1974 - 1983. ” *Journal of International Economics*: 129-14.
- [48] Huang, W., Lai, K.K., and Nakamori, Y. (2004). Forecasting foreign exchange rates with artificial neural networks: A review. *International Journal of Information Technology & Decision Making*, 3(1): 145-165.
- [49] Huo, F. & Poo A.N., (2013) “Nonlinear autoregressive network with e xogenous inputs based contour error reduction in CNC machines,” *International Journal of Machine Tools and Manufacture*, vol. 67, pp. 45–52.

- [50] Hwang, S.Y., & Basawa, I.V., (1994). “Large sample inference based on multiple observations from nonlinear autoregressive processes”, *Stochastic Processes and their Applications*, vol. 49, no. 1, pp. 127–140. OCLC number: 1789401 ISSN: 0304-4149 (print); 1879-209X (web).
- [51] Hyndman R.J., & Khandakar, Y. (2008). “Automatic Time Series Forecasting: The forecast Package for R”. *Journal of Statistical Software*, Volume 27, Issue 3. ISSN 1548-7660.
- [52] Hyndman, R.J., & Koehler, A.B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*. 22(4), 679-688.
- [53] Hyndman, R.J., Athanasopoulos (2013). *Forecasting Principles and Practice*. OTexts Melbourne, Australia.
- [54] Ibrahim, A. H. (2014). *Data Normalization and Standardization for Neural Networks Output Classification*. Data Mining, Machine Learning.
- [55] Kapetanios, G., (2006). “Nonlinear autoregressive models and long memory,” *Economics Letters*, vol. 91, no. 3, pp. 360–368. LCCN: 85642356 OCLC number: 4596608.
- [56] Khashei, M. & Bijari, M. (2011) “Which Methodology is Better for Combining Linear and Nonlinear Models for Time Series Forecasting?” *Journal of Industrial and Systems Engineering* Vol. 4, No. 4, pp 265-285.
- [57] Khashei, M., Bijari, M. & Ardali, G.A. (2009). Improvement of Autoregressive Integrated Moving Average Models Using Fuzzy Logic and Artificial Neural Networks (ANNs). *Neurocomputing*, 72: 956-967.
- [58] Manjang, S., Diongue, A.K., Odongo, L., (2014). “Modeling and Forecasting Gambia’s Inflation Rates” in *International Journal of Economics and Finance*; Vol. 6, No. 10; 2014 ISSN 1916-971X E-ISSN 1916-9728 Mc Clelland, AND the PDP Research Group. Cambridge, MA: The MIT Press: 318-362.
- [59] McCulloch, W.W. & Pitts, W., (1943) A Logical Calculus Ideas Imminent in Nervous Activity. *Bulletin of Mathematical Biophysics*, vol. 5, 115-133.
- [60] McDonald, P. (2007) *Low RPM and Policy*. Oxford Institute of Ageing. AGEING HORIZONS, Issue No. 7, 22–27.
- [61] Medeiros, M.C., Teräsvirta, T., & Rech, G. (2006). Building neural network models for time series: a statistical approach. *Journal of Forecasting*, 25(1), 49–75.
- [62] Mema, B. & Zela, K., Predictive Analysis of Educational Trends: A Time Series Approach to State Matriculation Exam Performance. (2024). *Journal of Educational and Social Research*, 14(5), 371. <https://doi.org/10.36941/jesr-2024-0145>.
- [63] Mitchell, T. (1997) *Machine Learning*, Mc Graw Hill. 414 pages. ISBN 0070428077.
- [64] Mizraeh, B., (1992). Multivariate nearest-neighbour forecasts of EMS exchange rates DOI: 10.1002/jae.3950070511. *Journal of Applied Econometrics*. Volume 7, Issue Supplement S1, December 1992 Pages S151–S163.
- [65] Murphy, K.P. (2012) *Machine Learning: A Probabilistic Perspective* (Adaptive Computation and Machine Learning series) 1st Edition. ISBN-10: 0262018020 ISBN-13: 978-0262018029.

- [66] Negnevitsky, M. (2011) *Artificial Intelligence: A Guide to Intelligent Systems*. 3rd Edition. Pearson Education Canada. ISBN-10: 1408225743 ISBN-13: 978-1408225745.
- [67] Pawlus, W., Karimi, H.R., & Robbersmyr, K.G., (2013). “Data-based modeling of vehicle collisions by nonlinear autoregressive model and feedforward neural network,” *Information Sciences, ELSEVIER* vol. 235, pp. 65–79.
- [68] Pelikan, E., Groot, C., & Wurtz, D. (1992). Power consumption in West-Bohemia: improved forecasts with decorrelating connectionist networks. *Neural network world* 2, 701-712.
- [69] Peng, R. D., (2014). “R Programming for Data Science”, Lean Publishing.
- [70] Poli, I., & Jones, R.D., (1994). A Neural netmodel for prediction. *Journal of the American Statistical Association*, 89(425) 117-121.
- [71] Rather, A.M., Agarwal, A., & Sastry, V. N. (2015) Recurrent neural network and a hybrid model for prediction of stock returns. *J Exp Syst Appl* 42:3234–3241.
- [72] Rau, R. (2005). *Seasonality in human mortality. A demographic approach*. Un. Rostock, Germany.
- [73] Robbins SP, Judge TA. *Organizational Behavior*. Pearson; 2019.
- [74] Rodríguez Rivero, C., Pucheta, J., Laboret, S., Patiño, D., Sauchelli, V. (2015), *Forecasting Short Time*.
- [75] Ruiz, L.G.B., Cuéllar, M.P., Calvo-Flores, M.D., Jiménez, M.D.C.P. (2016), An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings, *Energies*, 9, p. 684. <https://doi.org/10.3390/en9090684>.
- [80] Ryan RM, Deci EL. *Self-Determination Theory: Basic Psychological Needs in Motivation, Development, and Wellness*. Guilford; Press; 2017.
- [81] Sajid, M.R., Maqsood, F. and Rani M. (2011) Determinants of RPM: A Neural Network Approach. *Middle-East Journal of Scientific Research* 8 (2): 440-449, 2011 ISSN 1990-9233 © IDOSI Publications.
- [82] Sallehuddin, R., & Shamsuddin, S.M. (2008) “Hybrid ization Model of Linear and Nonlinear Time Series Data for Forecasting”. *Second Asia International Conference on Modeling & Simulation*. ISBN: 978-0-7695-3136-6 (IEEE).
- [83] Samia, A., Kaouther, N., & Abdelwahed, T., (2012) “A Hybrid ARIMA and Artificial Neural Networks model to forecast air quality in urban areas: case of Tunisia”. *Advanced Materials*.
- [84] Sarno, L., & Taylor, M.P. (2002) “Purchasing power parity and the real exchange rate.” *IMF Staff Papers* Vol. 49, No. 1 © 2002 International Monetary Fund.
- [85] Savas, F.N. (2013) “Forecast Comparison of Models Based on SARIMA and the Kalman Filter for Inflation”. *Uppsala University*.
- [86] Saz, G., (2011) “The Efficacy of SARIMA Models for Forecasting Inflation Rates in Developing Countries: The Case for Turkey.” *International Research Journal of Fin. and Ec*, Vo l. 62, pp. 111-142.
- [87] Series with Missing Data by Means of Energy Associated to Series, *Applied Mathematics*, 6, pp. 1611-1619. <https://doi.org/10.4236/am.2015.69143>.

- [88] Smith, M. (2013) Neural networks for statistical modeling. Van Nostrand Reinhold.
- [89] Shanker, M., (2006) Effect of data standardization on neural network training, Omega 24(4) 385–397.
- [90] Shao, Y. E., (2013) “Prediction of currency volume issued in Taiwan using a hybrid artificial neural network and multiple regression approach,” Mathematical Problems in Engineering, vol. 2013, Article ID 676742, 9 pages.
- [91] Sheela, K. G. & Deepa, S. N., (2013) Review on Methods to Fix Number of Hidden Neurons in Neural Networks. Mathematical Problems in Engineering. Volume 2013, 11 pages.

SHTOJCA A

MODELET ARIMA PËR SERITË KOHORE TË ANALIZUARA

A.1 MODELI ARIMA PËR ÇMIMIN DITOR TË BITCOIN-IT

Procesi i përcaktimit të modelit optimal u realizua nga funksionit `auto.arima()` në gjuhën R, i cili identifikoi disa struktura të modeleve të tipit sezonal ARIMA. Modelet e krahasuara sipas (AIC) janë:

Modeli SARIMA	AIC
ARIMA(2,0,2)(1,1,1)[7]	3153.84
ARIMA(0,0,0)(0,1,0)[7]	3333.232
ARIMA(1,0,0)(1,1,0)[7]	3175.09
ARIMA(0,0,1)(0,1,1)[7]	3210.757
ARIMA(2,0,2)(0,1,1)[7]	3246.456
ARIMA(2,0,2)(2,1,1)[7]	3145.399
ARIMA(2,0,2)(2,1,0)[7]	3159.9
ARIMA(2,0,2)(2,1,2)[7]	3147.558
ARIMA(2,0,2)(1,1,0)[7]	3180.796
ARIMA(1,0,2)(2,1,1)[7]	3143.533
ARIMA(1,0,1)(2,1,1)[7]	3142.945
ARIMA(0,0,0)(2,1,1)[7]	3313.529
ARIMA(1,0,1)(1,1,1)[7]	3150.228
ARIMA(1,0,1)(2,1,0)[7]	3156.997
ARIMA(1,0,1)(2,1,2)[7]	3145.072
ARIMA(1,0,1)(1,1,0)[7]	3176.94
ARIMA(0,0,1)(2,1,1)[7]	3209.041
ARIMA(2,0,1)(2,1,1)[7]	3144.67
ARIMA(1,0,2)(1,1,1)[7]	3140.831
ARIMA(1,0,0)(1,1,1)[7]	3148.217
ARIMA(1,0,0)(2,1,0)[7]	3154.904
ARIMA(1,0,0)(2,1,2)[7]	3142.937
ARIMA(2,0,0)(2,1,1)[7]	3143.17

Modeli më i mirë, bazuar në vlerën më të ulët të AIC, rezultoi të jetë:

Modeli përfundimtar : ARIMA(1,0,2)(1,1,1)[7] Polinomet

e modelit janë:

- **Polinomi i vonesës jo-sezonal (MA):** $\Theta(L) = 1 - 0,0245L - 0,1126L^2$
- **Polinomi i vonesës jo-sezonal (AR):** $\Phi(L) = 1 - 0,8756L$
- **Polinomi sezonal i MA:** $\Theta(L) = 1 - 0,6871L^7$
- **Polinomi sezonal i AR:** $\Phi(L) = 1 - 0,0324L^7$

Përfundimi i modelit:

$$y_t = 0.8756y_{t-1} + 1.0324y_{t-7} - 0.9039y_{t-8} + 0.0324y_{t-14} + 0.02837y_{t-15} + \varepsilon_t \\ - 0.6871\varepsilon_{t-7} - 0.0245\varepsilon_{t-1} + 0.01683\varepsilon_{t-8} - 0.1126\varepsilon_{t-2} \\ + 0.0773\varepsilon_{t-9}$$

A.2 MODELI ARIMA PËR REZULTATET E PROVIMEVE TË MATURËS SHTETËRORE

Modeli SARIMA	AIC
ARIMA(2,1,2)(1,1,1)[12]	297.1262
ARIMA(0,1,0)(0,1,0)[12]	495.4171
ARIMA(1,1,0)(1,1,0)[12]	322.782
ARIMA(0,1,1)(0,1,1)[12]	383.6374
ARIMA(2,1,2)(0,1,1)[12]	372.8456
ARIMA(2,1,2)(1,1,0)[12]	295.0964
ARIMA(1,1,2)(1,1,0)[12]	290.1144
ARIMA(2,1,1)(1,1,0)[12]	288.1357
ARIMA(0,1,0)(1,1,0)[12]	389.7315
ARIMA(1,1,1)(0,1,0)[12]	433.0519
ARIMA(1,1,1)(1,1,1)[12]	289.7178
ARIMA(0,1,1)(1,1,0)[12]	347.7034
ARIMA(1,1,1)(1,1,0)[12]	290.7069

Modelet më të përshtatshme u vlerësuan sipas AIC, ku modeli më i mirë rezultoi:

Modeli përfundimtar : ARIMA(2,1,1)(1,1,0)[12]

Polinomet e modelit janë:

- **Polinomi i MA:** $\Theta(L) = 1 - 0,6681L$
- **Polinomi i AR:** $\phi(L) = 1 - 1,0231L + 0,1084L^2$
- **Polinomi sezonal i AR:** $\Phi(L) = 1 - 0,562L^{12}$
- **Polinomi sezonal i MA:** $\Theta(L) = 1$

Përfundimi i modelit:

$$y_t = 1.0231y_{t-1} - 0.1084y_{t-2} + 1.562y_{t-12} - 1.5981y_{t-13} + 0.169y_{t-14} - 0.562y_{t-24} + 0.575y_{t-25} - 0.0609y_{t-26} + \varepsilon_t - 0.6681\varepsilon_{t-1}$$

A.3 MODELI ARIMA PËR MOTIVIMIN E LEKTORËVE NË FAKULTETET E INXHINIERISË

Modeli SARIMA	AIC
ARIMA(2,1,2)(1,1,1)[12]	866.2205
ARIMA(0,1,0)(0,1,0)[12]	991.2743
ARIMA(1,1,0)(1,1,0)[12]	909.9454
ARIMA(0,1,1)(0,1,1)[12]	919.5581
ARIMA(2,1,2)(0,1,1)[12]	900.6686
ARIMA(2,1,2)(2,1,1)[12]	833.628
ARIMA(2,1,2)(2,1,0)[12]	831.4459
ARIMA(1,1,2)(2,1,0)[12]	830.9384
ARIMA(2,1,1)(2,1,1)[12]	828.9836
ARIMA(0,1,0)(2,1,0)[12]	853.9893
ARIMA(1,1,1)(1,1,0)[12]	907.1086
ARIMA(1,1,1)(2,1,1)[12]	831.1234
ARIMA(0,1,1)(2,1,0)[12]	830.8651
ARIMA(2,1,1)(2,1,0)[12]	831.8985
ARIMA(1,1,0)(2,1,0)[12]	841.045

Modelet e vlerësuara me auto.arima() sugjeruan si më të përshtatshëm modelin:

Modeli përfundimtar: ARIMA(2,1,1)(2,1,1)[12]

Polinomet përkatëse janë:

- **MA (josezonal):** $\Theta(L) = 1 - 0,6681L$
- **AR (josezonal):** $\Phi(L) = 1 - 1,0231L + 0,1084L^2$
- **MA (sezonal):** $\Theta(L) = 1$
- **AR (sezonal):** $\Phi(L) = 1 + 0,5620L^{12}$

Modeli përfundimtar është:

$$y_t = 1.7118y_{t-1} + 0.164y_{t-2} + 0.1584y_{t-3} + 1.64y_{t-12} + 1.3y_{t-13} \\ + 0.47y_{t-14} + 0.1584y_{t-15} + 0.2687y_{t-24} + 0.3697y_{t-25} + 0.04y_{t-26} + 0.05y_{t-27} - \\ 0.2687y_{t-36} + 0.27y_{t-37} + 0.1y_{t-38} + 0.04y_{t-39} + \varepsilon_t + 0.5239\varepsilon_{t-1} - 0.5134\varepsilon_{t-12} - 0.26\varepsilon_{t-13}$$

A.4 MODELI ARIMA PËR KURSIN E KËMBIMIT EURO/LEK

Modeli SARIMA	AIC
ARIMA(2,1,2)(1,1,1)[12]	575.2234
ARIMA(0,1,0)(0,1,0)[12]	698.1373
ARIMA(1,1,0)(1,1,0)[12]	585.0829
ARIMA(0,1,1)(0,1,1)[12]	588.1903
ARIMA(2,1,2)(0,1,1)[12]	591.6728
ARIMA(2,1,2)(2,1,1)[12]	545.852
ARIMA(2,1,2)(2,1,0)[12]	545.3883
ARIMA(1,1,2)(2,1,0)[12]	541.8885
ARIMA(1,1,1)(2,1,0)[12]	540.0566
ARIMA(0,1,0)(2,1,0)[12]	558.7842
ARIMA(1,1,1)(1,1,0)[12]	587.0562
ARIMA(1,1,1)(2,1,1)[12]	540.6981
ARIMA(0,1,1)(2,1,0)[12]	538.5773
ARIMA(0,1,2)(2,1,0)[12]	538.0032
ARIMA(0,1,1)(1,1,0)[12]	588.3145
ARIMA(0,1,1)(2,1,1)[12]	539.274

Modeli më i përshtatshëm i përzgjedhur nga `auto.arima()` është:

Modeli përfundimtar :ARIMA(0,1,2)(2,1,0)[12]

Polinomet e modelit janë:

- **MA:** $\Theta(L) = 1 + 0.4725L + 0.1178L^2$
- **AR:** $\Phi(L) = 1$
- **MA sezonal:** $\Theta(L) = 1$
- **AR sezonal:** $\Phi(L) = 1 + 0.7149L^{12} + 0.3066L^{24}$

Modeli i finalizuar është:

$$y_t = 1.29y_{t-1} + 0.8756y_{t-12} + 1.7149y_{t-13} + 0.41y_{t-24} + 0.3066y_{t-25} + 0.3066y_{t-36} + 0.3066y_{t-37} + \varepsilon_t + 0.4725\varepsilon_{t-1} + 0.1178\varepsilon_{t-2}$$

PËRFUNDIM I SHTOJCËS A

Shtojca A paraqet në mënyrë të detajuar strukturën matematikore dhe rezultatet numerike të katër modeleve SARIMA të zbatuara mbi seri kohore reale të përzgjedhura në këtë tezë. Të gjitha modelet janë ndërtuar përmes metodologjisë Box-Jenkins dhe përzgjedhja është kryer sipas kriterëve të informacionit AIC, AICc dhe BIC. Këto modele shërbejnë si bazë për analizën e mëtejshme parashikuese dhe vlerësimin krahasues të performancës.

SHTOJCA B

KODI I PROGRAMIMIT NË R PËR MODELET E PARASHIKIMIT TË SERIVE KOHORE

Kjo shtojcë përmban skriptet e përdorura në gjuhën programuese R për ndërtimin, testimin dhe parashikimin me modelet SARIMA, NAR dhe modelet hibride ARIMA-ANN për seritë kohore të analizuar në këtë punim.

B.1 – SERIA KOHORE: MOTIVIMI I LEKTORËVE NË FAKULTETIN E INXHINIERISË

```
# Paketat e nevojshme
library(tseries)
library(forecast)
library(neuralnet)

# Leximi i të dhënave
MLFI <- read.csv("C:/Users/ADMN/Desktop/MLFI.csv", sep=";", dec=",", header=TRUE)
MLFI <- ts(MLFI[,2], start=c(2000,1), frequency=12)

# Vizualizimi i serisë
plot(MLFI, main="MLFI", col="blue")

# Testi i qëndrueshmërisë (ADF)
adf.test(MLFI, alternative="stationary", k=trunc((length(MLFI)-1)^(1/3)))
adf.test(diff(MLFI), alternative="stationary", k=trunc((length(MLFI)-1)^(1/3)))

# Shfaqja e komponentëve të vonesave
tsdisplay(diff(MLFI,12))

# Krijimi i modelit SARIMA
fit_MLFI <- auto.arima(MLFI, d=1, D=1, max.p=5, max.q=5, max.P=2, max.Q=2, max.order=5,
                      max.D=1, stationary=FALSE, trace=TRUE)
summary(fit_MLFI)
tsdisplay(residuals(fit_MLFI))
Box.test(residuals(fit_MLFI), lag=16, fitdf=12, type="Ljung")
jarque.bera.test(residuals(fit_MLFI))

# Parashikimi dhe vizualizimi
forecast_MLFI <- forecast(fit_MLFI, h=12)
plot(forecast_MLFI)
```

B.2 – SERIA KOHORE: KURSI I KËMBIMIT EURO/LEK

```
# Leximi i të dhënave
euro_lek <- read.csv("C:/Users/ADMN/Desktop/euro-lek.csv", sep=";", dec=",", header=TRUE)
euro_lek <- ts(euro_lek[,2], start=c(2000,1), frequency=12)

# Diferencimi dhe testet
adf.test(diff(euro_lek), alternative="stationary", k=trunc((length(euro_lek)-1)^(1/3)))
tsdisplay(diff(euro_lek,12))

# Krijimi i modelit SARIMA
fit_euro <- Arima(euro_lek, order=c(0,1,2), seasonal=c(2,1,0))
summary(fit_euro)
tsdisplay(residuals(fit_euro))
Box.test(residuals(fit_euro), lag=16, fitdf=12, type="Ljung")

# Vizualizimi
plot(forecast(fit_euro, h=12))
```

B.3 – SERIA KOHORE: ÇMIMI DITOR I BITCOIN-IT

```
# Leximi dhe konvertimi në seri kohore
Bit <- read.csv("C:/Users/ADMN/Desktop/Bit.csv", sep=";", dec=",", header=TRUE)
Bit <- ts(Bit[,2], start=c(1995,8), frequency=12)

# Analiza stacionariteti dhe modelimi
adf.test(diff(Bit), alternative="stationary", k=trunc((length(Bit)-1)^(1/3)))
tsdisplay(diff(Bit,1))
tsdisplay(diff(Bit,13))

# Modeli SARIMA
fit_Bit <- Arima(Bit, order=c(2,1,1), seasonal=c(1,1,0))
summary(fit_Bit)
tsdisplay(residuals(fit_Bit))
Box.test(residuals(fit_Bit), lag=9, fitdf=3, type="Ljung")

# Parashikimi dhe grafiku
plot(forecast(fit_Bit, h=7))
```

B.4 – SERIA KOHORE: REZULTATET E PROVIMEVE TË MATURËS SHTETËRORE

```
# Leximi i të dhënave
RPM <- read.csv("C:/Users/ADMN/Desktop/RPM.csv", sep=";", dec=",", header=TRUE)
RPM <- ts(RPM[,2], start=c(1999,1), frequency=12)

# Diferencim dhe analiza
tsdisplay(RPM)
tsdisplay(diff(RPM,12))

# Krijimi i modelit SARIMA
fit_RPM <- auto.arima(RPM, d=0, D=1, max.p=5, max.q=5, max.P=2, max.Q=2,
                    max.order=5, stationary=FALSE, seasonal=TRUE, trace=TRUE)

# Rezultate dhe diagnostikim
summary(fit_RPM)
tsdisplay(residuals(fit_RPM))
Box.test(residuals(fit_RPM), lag=8, fitdf=1, type="Ljung")

# Parashikimi
forecast_RPM <- forecast(fit_RPM, h=58)
plot(forecast_RPM)
```

SHËNIME:

- Të dhënat origjinale për çdo seri janë ruajtur në format CSV dhe janë të strukturuar sipas kolonës së vlerave të kohës dhe indeksit kohor përkatës.
- Të gjitha funksionet janë të bazuara në paketat forecast, tseries dhe neuralnet.
- Modelet hibride janë ndërtuar me kombinimin e rezultateve të mbetura të SARIMA dhe inputeve me vonesë për rrjetin nervor.

SHTOJCA C

PYETËSOR PËR MOTIVIMIN E PEDAGOGËVE NË FAKULTETIN E INXHINIERISË

I. TË DHËNA DEMOGRAFIKE

1. **Qyteti ku jepni mësim**
 - Tiranë
 - Elbasan
 - Tjetër: _____
2. **Grada akademike**
 - MSc
 - Dr
 - Prof. Assoc.
 - Prof. Titullar
3. **Gjinia**
 - Mashkull
 - Femër
 - Preferoj të mos përgjigjem
4. **Mosha**
 - <30 vjeç
 - 31–40 vjeç
 - 41–50 vjeç
 - >50 vjeç
5. **Statusi martesor**
 - Beqar/e
 - I/e martuar
 - I/e divorcuar
 - I/e ve
6. **Përvoja në mësimdhënie**
 - <5 vjet
 - 6–15 vjet
 - >15 vjet
7. **Gjendja financiare e perceptuar**
 - Shumë e mirë
 - E mirë
 - Mesatare
 - Jo e mirë

8. **Merrni bonuse financiare në punë?**

Po

Jo

9. **Jeni i/e kënaqur me punën tuaj aktuale?**

Po

Jo

II. FAKTORËT MOTIVUES (JU LUTEM VLERËSONI SECILËN DEKLARATË)

Shkalla e vlerësimit:

1 – Aspak

2 – Pak

3 – Mesatarisht

4 – Shumë

Nr. Deklarata

1 2 3 4

- | | | | | |
|--|--------------------------|--------------------------|--------------------------|--------------------------|
| 1. Më vlerësojnë për kontributin dhe progresin që kam bërë në punë | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 2. Kam mundësi të përvetësoj njohuri dhe aftësi të reja në punë | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 3. Kam mundësi të marr pjesë në trajnime dhe seminare profesionale | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 4. Më ofrohen mundësi për rritje profesionale | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 5. Kam lirinë të zgjedh mënyrën time të punës | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 6. Marr përgjegjësi të plotë për detyrat e mia | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 7. Marr mbështetje të vazhdueshme nga drejtuesit për të rritur produktivitetin | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 8. Detyrat e mia janë gjithmonë të qarta dhe në përputhje me pozicionin tim | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 9. Natyra dhe intensiteti i punës është i përballueshëm për mua | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 10. Kam një orar fleksibël pune | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 11. Kam një pagë të mirë | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 12. Punoj në një ambient të sigurt dhe komod | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| 13. Punoj me staf bashkëpunues | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |