

UNIVERZA V MARIBORU  
EKONOMSKO-POSLOVNA FAKULTETA

Doktorska disertacija

**UPORABA UMETNE INTELIGENCE PRI UPRAVLJANJU  
PORTFELJA DELNIC**

Marec, 2022

UNIVERZA V MARIBORU  
EKONOMSKO-POSLOVNA FAKULTETA

Doktorska disertacija

**UPORABA UMETNE INTELIGENCE PRI UPRAVLJANJU  
PORTFELJA DELNIC**

asist. Dušan Fister, mag. inž. meh., CQRM  
Mentor: red. prof. ddr. Timotej Jagrič, CQRM  
Somentor: red. prof. dr. Matjaž Perc  
Lektorica: Nuša Grah, prof. slov. in angl.  
UDK: 004.8:336.71(043.3)

Marec, 2022

## **ZAHVALA**

Iskreno se zahvaljujem mojemu mentorju, red. prof. ddr. Timoteju Jagriču, CQRM, za strokovno vodenje, usmerjanje, svetovanje in vse skupne trenutke, ki sva jih podoživela pri mojem osvajanju ekonomije.

Zahvaljujem se mojemu somentorju, red. prof. dr. Matjažu Percu, za vedno dobrodošlo pomoč in nasvet. Hvala zunanjima sodelavcema, red. prof. dr. Štefan Bojnecu in doc. dr. Sašu Karakatiču, za vse predlagane izboljšave.

Hvala Javni agenciji za raziskovalno dejavnost Republike Slovenije za dano priložnost, da sem lahko v zadnjih letih deloval kot mladi raziskovalec.

Najlepša hvala sodelavcem Instituta za finance in umetno inteligenco za vsa skupna sodelovanja. Hvala mojim tesnim prijateljem – sodelavcem in EPF-u za vso prijaznost.

Posebna zahvala gre družini.

## POVZETEK

*Izziv dela predstavljajo snovanje, načrtovanje in praktična izvedba avtomatiziranega trgovalnega sistema, ki neodvisno in brez posredovanja uporabnikov sprejema in izvaja trgovalne odločitve. Jedro trgovalnega sistema predstavlja trgovalna strategija, ki spremlja pretekle ter aktualne podatke borznih kotacij, izvaja tehnično analizo in, če je tega sposobna, se prilagaja sprotnim razmeram na finančnih trgih. Obravnavamo dve skupini trgovalnih strategij, klasične, ki niso sposobne sprotnega prilagajanja niti učenja, in dve trgovalni strategiji na osnovi naprednih algoritmov umetne inteligence, eno izmed njih predstavnicu umetnih nevronskih mrež najnovejše tretje generacije. Izvedemo obširna simulacijska eksperimentiranja na osnovi nemškega delniškega trga v zadnjih desetih letih, zasnujemo in izvedemo pa tudi eksperimentiranja na namenski strojni opremi, ki močno pohitrijo kompleksnost časovnega izvajanja ter eksperimentiranja na analognem elektronskem vezju, s pomočjo katerega se podrobno seznanimo z načinom razširjanja informacij umetnih nevronskih mrež tretje generacije. Rezultati eksperimentov prinašajo tako vsebinske kot tehnične ugotovitve, najpomembnejšo med njimi, da se enoten model, ki hkrati trguje z večjim številom finančnih instrumentov obnaša podobno kot kopica posamično prilagojenih modelov na točno določen finančni instrument, kakor tudi novo ugotovljene izkušnje, vezane na razširjanje in izrabo najnovejše generacije umetnih nevronskih mrež.*

**Ključne besede:** *globoko učenje, dolgi kratkotrajni spomin, impulzna nevronska mreža, mehanski trgovalni sistem, hipoteza učinkovitega trga, evropski delniški trg*

# TITLE: ARTIFICIAL INTELLIGENCE FOR MANAGING THE PORTFOLIO OF STOCKS

## ABSTRACT

*Challenge of this work is about the design, planning and practical implementation of the automated trading system that independently and user-interference free generates the trading decisions and realizes them on the open market. The core of the trading system is a trading strategy that monitors past and current financial data, performs the technical analyses and, if capable adapts to the latest conditions on financial markets. Two groups of the trading strategies, the classics, traditionally not capable of adapting nor learning, and two adapting and learning capable trading strategies, based on the latest artificial intelligence methods, one of them a representative of the third-generation neural networks, are implemented. Comprehensive simulation experiments and tests are concluded using the data on German stock market in past ten years, with additional digital and purely analogue hardware experiments on the dedicated equipment, that demand significantly lower time complexities on one hand, and offer an outstanding chance to get familiarized with the concept of information propagation in the third-generation artificial neural networks. Results of experiments communicate both substantive and technical findings, more important among them, that the universal model that manages several financial instruments concurrently behaves similar as a bunch of specific models that are specialized for only a single financial instrument at a time, as well as newly discovered experiences on propagation and exploitation of the latest third-generation neural networks.*

**Key words:** *deep learning, long short-term memory, spiking neural network, mechanical trading system, efficient market hypothesis, European stock market*



# KAZALO

<b>1</b>	<b>UVOD</b>	<b>1</b>
<b>1.1</b>	<b>Opredelitev problema</b>	<b>1</b>
<b>1.2</b>	<b>Cilji doktorske disertacije</b>	<b>2</b>
<b>1.3</b>	<b>Teza doktorske disertacije</b>	<b>2</b>
<b>1.4</b>	<b>Izvirni znanstveni prispevki</b>	<b>2</b>
<b>1.5</b>	<b>Predpostavke in omejitve</b>	<b>3</b>
<b>1.6</b>	<b>Metode raziskovanja</b>	<b>4</b>
<b>2</b>	<b>TEORETIČNI PREGLED</b>	<b>5</b>
<b>2.1</b>	<b>Hipoteza učinkovitih trgov</b>	<b>5</b>
<b>2.2</b>	<b>Učinkovit portfelj</b>	<b>8</b>
2.2.1	Ekonomska – sektorska – temeljna analiza	10
2.2.2	Tehnična analiza	12
<b>2.3</b>	<b>Zajeta podjetja</b>	<b>13</b>
<b>2.4</b>	<b>Baza podatkov</b>	<b>14</b>
2.4.1	Izračuni tehničnih indikatorjev	16
<b>2.5</b>	<b>Komentar borznih gibanj</b>	<b>18</b>
2.5.1	Analiza podobnosti z drugimi svetovnimi borznimi trgi	19
2.5.2	Analiza dogajanja na finančnih trgih in finančna stabilnost EU v obdobju 2007–2020	22
2.5.3	Analiza dolgoročnega spomina borznih kotacij s Hurstovim eksponentom	26
<b>2.6</b>	<b>Predlagana rešitev</b>	<b>31</b>
<b>3</b>	<b>Finančni trgi, Mehanski Trgovalni Sistem in LSTM</b>	<b>35</b>
<b>3.1</b>	<b>Finančni trgi</b>	<b>35</b>
<b>3.2</b>	<b>Nevronske mreže s povratno zanko</b>	<b>39</b>
3.2.1	Rekurentna nevronska mreža	39
3.2.2	Nevronska mreža z dolgim kratkotrajnim spominom	40
<b>3.3</b>	<b>Sinteza LSTM</b>	<b>42</b>
3.3.1	Odvisna spremenljivka	43
3.3.2	Učni algoritem	44
<b>3.4</b>	<b>Eksperimenti</b>	<b>46</b>
3.4.1	Merila za ocenjevanje kakovosti trgovalnih strategij	48
3.4.2	Preizkus koncepta	49
3.4.3	Preizkus robustnosti	51
3.4.4	Detajlna analiza trgovanja	53

<b>3.5</b>	<b>Diskusija</b>	<b>55</b>
<b>4</b>	<b>EKSPERIMENTIRANJE z impulzno nevronske mrežo</b>	<b>57</b>
<b>4.1</b>	<b>Uvod</b>	<b>57</b>
4.1.1	Modeliranje LIF nevrona	59
4.1.2	Učni algoritmi SNN	62
<b>4.2</b>	<b>Izdelava RTC-SNN elektronskega vezja</b>	<b>63</b>
4.2.1	Poenostavljena zbirka podatkov IRIS	65
4.2.2	Fotografije in načrt vezja	66
4.2.3	Preizkus koncepta: učenje RTC-SNN s postopkom modificiranega STDP (RTC-SNN+ m. STDP)	71
4.2.4	Preizkus koncepta: napovedovanje z RTC-SNN+m. STDP	75
<b>4.3</b>	<b>In-silico simulacije upravljanja portfelja delnic s SNN mrežo s postopkom modificiranega STDP (simulacije in-silico SNN+m. STDP)</b>	<b>76</b>
4.3.1	Simulacije in-silico v programskem okolju MATLAB (SNN+m. STDP)	77
4.3.2	Simulacije in-silico na FPGA in primerjava časovne kompleksnosti (FPGA-SNN+m. STDP)	80
<b>4.4</b>	<b>Nadgradnja učenja SNN z algoritmom DE (SNN+DE)</b>	<b>81</b>
4.4.1	Simulacije in-silico SNN+DE – poenostavljena zbirka podatkov IRIS	83
4.4.2	Preizkus RTC-SNN+DE – poenostavljena zbirka podatkov IRIS	87
4.4.3	Simulacije in-silico SNN+DE – trgovanje s SNN	89
<b>4.5</b>	<b>Diskusija</b>	<b>92</b>
<b>5</b>	<b>SKLEP</b>	<b>95</b>
	<b>LITERATURA IN VIRI</b>	<b>101</b>



## KAZALO SLIK

<i>Slika 1: Markowitzeva učinkovita fronta</i>	8
<i>Slika 3: Delniški indeks DAX30 v obdobju od 1. januarja 2010 do 12. maja 2020</i>	19
<i>Slika 4: Koincidenca nemškega borznega trga (DAX30, »<sup>^</sup>GDAXI«) z ostalimi svetovnimi borznimi trgi</i>	21
<i>Slika 5: Makroekonomski odtis nemškega gospodarstva v opazovanem obdobju</i>	23
<i>Slika 2: Izračuni Hurstovega eksponenta</i>	30
<i>Slika 6: Odvijanje RNN skozi čas</i>	39
<i>Slika 7: Osnovna zgradba LSTM</i>	41
<i>Slika 8: Posamični LSTM-model</i>	43
<i>Slika 9: Enotni LSTM-model</i>	43
<i>Slika 10: Razširjanje primerka od <math>xt - Ts</math> do <math>xt</math></i>	46
<i>Slika 11: Potek trgovanja LSTM ITS</i>	50
<i>Slika 12: Primer presinaptičnega in postsinaptičnega nevrona, ki ju povezuje sinapsa (zgoraj) in pripadajoč elektronski model (spodaj)</i>	59
<i>Slika 13: Fotografije izdelanega vezja RTC-SNN in pripadajočih komponent</i>	67
<i>Slika 14: Fotografije izdelanega vezja RTC-SNN in pripadajočih komponent</i>	68
<i>Slika 15: Shematični prikaz »originalnih« sinapse in nevrona RTC-SNN</i>	69
<i>Slika 16: Shematični prikaz celotne mreže RTC-SNN</i>	70
<i>Slika 17: Preizkus učne sposobnosti mreže RTC-SNN+m. STDP - število pravilno klasificiranih primerkov poenostavljene zbirke podatkov IRIS <math>Z'</math> v odvisnosti od števila epoh</i>	75
<i>Slika 18: Trgovanje, simulacije in-silico SNN+m. STDP</i>	79
<i>Slika 19: Tržna kapitalizacija v odvisnosti od trgovalnih dni, 10 neodvisnih zagonov</i>	79
<i>Slika 20: Napredovanje najboljše vrednosti ocenitvene funkcije <math>f_{best}</math> z naraščanjem števila generacij, simulacije in-silico SNN+DE</i>	86
<i>Slika 21: Napredovanje najboljše vrednosti ocenitvene funkcije v odvisnosti od naraščanja števila generacij, RTC-SNN+DE</i>	88
<i>Slika 22: Napredovanje najboljše vrednosti ocenitvene funkcije v odvisnosti od naraščanja števila generacij, simulacije in-silico SNN+DE, <math>N = 10</math> neodvisnih zagonov</i>	90
<i>Slika 23: Tržna kapitalizacija v odvisnosti od trgovalnih dni, simulacije in-silico SNN+DE</i>	91

## KAZALO TABEL

<i>Tabela 1: Ekonomska – sektorska – temeljna analiza</i>	11
<i>Tabela 2: Seznam podjetij, pridobljen s spletne strani Finanzen.net v maju 2020, ki smo jih obravnavali v raziskavi</i>	13
<i>Tabela 3: Primer baze podatkov za nemško delnico Lufthansa v času od 2. januarja 2019 do 7. januarja 2019</i>	15
<i>Tabela 4: Skupina pojasnjevalnih spremenljivk, pojasnjevalne spremenljivke in število pojasnjevalnih spremenljivk v določeni skupini in skupno</i>	15
<i>Tabela 5: Nadzorni parametri LSTM</i>	47
<i>Tabela 6: Preizkus robustnosti med enotnim in posamičnim modelom. Število zagonov <math>N = 10</math></i>	52
<i>Tabela 7: Rezultati detajlne analize treh klasičnih ITS ter enotne in posamične LSTM ITS</i>	53
<i>Tabela 8: Nabor uporabljenih elektronskih komponent</i>	64
<i>Tabela 9: Deskriptivna statistika poenostavljene zbirke podatkov IRIS <math>Z'</math></i>	65
<i>Tabela 10: Nadzorni parametri RTC-SNN+m. STDP elektronskega vezja</i>	73
<i>Tabela 11: Preizkus na testnem vzorcu - kontingenčna tabela s povprečnimi rezultati na osnovi desetih zagonov testnega vzorca</i>	75
<i>Tabela 12: Nadzorni parametri simulacije in-silico SNN+m. STDP</i>	77
<i>Tabela 13: Rezultati in-silico preizkusov</i>	78
<i>Tabela 14: Časovna kompleksnost izvajanja učenja ter testiranja SNN+m. STDP</i>	80
<i>Tabela 15: Nadzorni parametri DE</i>	83
<i>Tabela 16: Nadzorni parametri simulacije in-silico SNN+DE</i>	84
<i>Tabela 17: Rezultati napovedovanja na učnem vzorcu poenostavljene zbirke podatkov IRIS, kontingenčna tabela, simulacije in-silico SNN+DE</i>	86
<i>Tabela 18: Časovna zahtevnost izvajanja učenja ter testiranja SNN</i>	87
<i>Tabela 19: Nadzorni parametri RTC-SNN+DE</i>	87
<i>Tabela 20: Rezultati napovedovanja na učnem vzorcu poenostavljene zbirke podatkov IRIS, kontingenčna tabela, RTC-SNN+DE</i>	89
<i>Tabela 21: Nadzorni parametri simulacij in-silico SNN+DE</i>	90
<i>Tabela 22: Primerjava med metodama AI po parametričnem t-testu (levo) in neparametričnem Mann-Whitney testu (desno, oboje p-vrednosti), popravljeno po Holm-Bonferroni metodi, <math>N = 10</math></i>	94

## SEZNAM OKRAJŠAV

AI	Umetna inteligenca (angl. Artificial Intelligence)
ANN	Umetna nevronska mreža (angl. Artificial Neural Network)
ATS	Avtomatski trgovalni sistem
BDP	Bruto domači proizvod (angl. Gross Domestic Product)
CB	Centralna banka
CDS	Posel kreditnih zamenjav (angl. Credit Default Swap)
CISS	Kazalnik sistemskega stresa (angl. Composite Indicator of Systemic Stress)
DE	Diferencialna Evolucija (angl. Differential Evolution)
EBA	Evropski bančni organ (angl. European Banking Authority)
EBIT	Prihodki pred obrestmi in davki (angl. Earning Before Interest and Taxes)
ECB	Evropska centralna banka (angl. European Central Bank)
EMH	Hipoteza učinkovitega trga (angl. Efficient Market Hypothesis)
EU	Evropska Unija
FED	Ameriška centralna banka (angl. Federal Reserve)
FP	Napačno razvrščeni pozitivni primerki (angl. False Positive)
FN	Napačno razvrščeni negativni primerki (angl. False Negative)
FPGA	Programirljiva matrika logičnih vrat (angl. Field Programmable Gate Array)
FPGA-SNN	SNN izvedena na FPGA
HICP	Harmoniziran indeks življenjskih potrebščin (angl. Harmonized Index of Consumer Prices)
IMF	Mednarodni denarni sklad (angl. International Monetary Fund)
ITS	Investicijska trgovalna strategija (angl. Investment Trading Strategy)
LSTM	Dolgi kratkoročni spomin (angl. Long Short-Term Memory)
MACD	Drseča sredina konvergence divergence (angl. Moving Average Convergence Divergence)
MRO	Operacije glavnega refinanciranja (angl. Main Refinancing Operations)
MTS	Mehanski trgovalni sistem
QE	Kvantitetno sproščanje (angl. Quantitative Easing)
RNN	Nevronska mreža s povratno zanko (angl. Recurrent Neural Network)
RSI	Relativni indeks moči (angl. Relative Strength Index)
RTC	Logika upor, tranzistor in kondenzator (angl. Resistor, Transistor, Capacitor logic)
RTC-SNN	SNN izvedena na RTC
SNN	Impulzna nevronska mreža (angl. Spiking Neural Networks)
SNN+DE	SNN z učinkim postopkom DE
SNN+m. STDP	SNN z učinkim postopkom modificiranega STDP-ja
STDP	Plastičnost, odvisna od časovnosti impulzov (angl. Spike-Timing-Dependent Plasticity)
TP	Pravilno razvrščeni pozitivni primerki (angl. True Positive)
TN	Pravilno razvrščeni negativni primerki (angl. True Negative)
VIX	Indeks nestanovitnosti (angl. Volatility Index)



# 1 UVOD

Uvodno poglavje obravnava šest podpoglavij z namenom povabiti bralca k branju naloge. Poglavje se prične z opredelitvijo problema (izziva), kjer je nanizanih pet osnovnih tematik izziva, predstavljena je tudi osnovna organizacija naloge, ki je razdeljena v tri sklope; zaključek prvega podpoglavja podaja grobo definicijo mehanskega trgovalnega sistema. Drugo in tretje podpoglavje zajemata kratki opis ciljev doktorske disertacije in opredelitev teze ter dveh hipotez. Obe podpoglavji sta ključnega pomena, saj v grobem določata postopek in metodologijo eksperimentov in preizkusov, bralca pa dodatno podrobneje seznanita o načinu spoprijemanja z izzivom. Četrto podpoglavje opredeljuje izvirne znanstvene prispevke, medtem ko peto podpoglavje predpostavke in omejitve. Obe podpoglavji sta usklajeni s pregledom literature na področju avtomatiziranega trgovanja s finančnimi instrumenti. Končno sledi zadnje podpoglavje, ki se nanaša na uporabljene metode raziskovanja, glede na eksperimentalno naravnost te naloge je v ospredju izvajanje eksperimentov.

## 1.1 Opredelitev problema

Ekonomska teorija pravi (v kolikor velja učinkovitost trgov), da je tehnično trgovanje s finančnimi instrumenti na osnovi preteklih podatkov obsojeno na propad. Praksa po drugi strani kaže, da so avtomatizirani sistemi, namenjeni za trgovanje (mehanski trgovalni sistemi), in delež avtomatiziranih menjav v izjemnem porastu. Časovne konstante menjav, ki jih dandanes premagujejo vrhunsko izobraženi informatiki, dosegajo mili in nanosekunde. Fizična oddaljenost do finančnih centrov, sposobnost kablov prenašanja informacij in zmogljivost superračunalnikov so postale ključnega pomena, računalniki so postali odgovorni za 80 odstotkov izvedenih menjav<sup>1</sup> na finančnih trgih.

Izziv, s katerim se soočamo v tej doktorski disertaciji, se nanaša na razvoj novih algoritmov najnaprednejših metod AI za potrebe avtomatiziranega trgovanja z delnicami na delniškem trgu. Izziv razdelimo na več tematik:

1. Pridobivanje finančnih/borznihih podatkov za vsaj 10 let v preteklost za vse delnice v portfelju.
2. Implementiranje MTS, ki bo v odvisnosti od posamezne trgovalne strategije kupoval, prodajal ali držal delnice posameznega podjetja.
3. Implementiranje LSTM, ki se bo sproti posodabljala na najaktualnejše podatke.
4. Uporabo sproti posodablajočih se LSTM mrež za namene trgovanja na delniški borzi.
5. Implementiranje SNN na namenski strojni opremi, preizkušanje časovne kompleksnosti in uporaba za namene trgovanja na delniški borzi.

V doktorski disertaciji sprejmemo naslednji opis za MTS: Mehanski trgovalni sistem (Vanstone & Finnie, 2007) je avtomatiziran sistem, ki prejema vhodne borzne/finančne podatke in te podatke posreduje jedru – trgovalni strategiji. Ta na osnovi preteklih gibanj in prepoznanih trgovalnih vzorcev daje tri osnovne signale za nakup, držanje ali prodajo delnic, kar posreduje

---

<sup>1</sup> <https://www.cnbc.com/2019/06/28/80percent-of-the-stock-market-is-now-on-autopilot.html>

nazaj MTS-u, ki te odločitve realizira. MTS-u je (v simulaciji) dodeljeno določeno število prostih denarnih sredstev, s katerimi razpolaga pri trgovanju.

## **1.2 Cilji doktorske disertacije**

Doktorsko disertacijo smo razdelili v tri sklope, vsak sklop je osredotočen na svoj cilj. To so:

1. Implementirati nabor pasivne (kupi-in-drži) in klasičnih trgovalnih strategij, namenjenih kot orodje za primerjavo (angl. benchmark).
2. Implementirati obče in sproti posodabljačo se trgovalne strategije na osnovi LSTM; eksperimentalno preizkusiti sproti posodabljačo se LSTM na primeru trgovanja z delniškimi vrednostnimi papirji na finančnih trgih z uporabo dnevniških borznih in finančnih podatkov.
3. Implementirati in testirati pristopa delovanja SNN; navesti in kritično ovrednotiti sedanje algoritme učenja SNN ter tehniko kodiranja vhodnih podatkov; razviti elektronski (analogni) model SNN in preizkusiti njegovo delovanje s pomočjo razvojne množice podatkov IRIS za detajlno seznanitev s SNN; preizkusiti SNN v okviru MTS kot trgovalne strategije za trgovanje vrednostnih papirjev na finančnih trgih z uporabo dnevniških borznih in finančnih podatkov; razviti prototipno aplikacijo MTS-a s SNN trgovalno strategijo na namenski strojni opremi – FPGA; podati empirične napotke za uporabo SNN v praksi.

## **1.3 Teza doktorske disertacije**

Teza: Metode AI lahko kot trgovalne strategije uporabimo za trgovanje v mehanskem trgovalnem sistemu, pri tem pa glede na donosnost prekašajo klasične trgovalne strategije.

Hipoteza H1: Globoka LSTM kot ena izmed možnih orodij AI prekaša klasične trgovalne strategije.

Hipoteza H2: Nevronska mrežo tretje generacije (SNN) lahko kot trgovalno strategijo smiselno implementiramo v mehanski trgovalni sistem in jo uporabimo na FPGA.

## **1.4 Izvirni znanstveni prispevki**

Pričakovane izvirne znanstvene prispevke razvrstimo po naslednjih alinejah:

1. Obsežna primerjava številnih trgovalnih strategij (pasivna, klasične, LSTM, SNN) na primeru razpršenega (angl. diversified) portfelja delnic.
2. Uporaba evropskega (nemškega) borznega trga kot primera razpršenega portfelja delnic za preizkus mehanskega trgovanja z različnimi trgovalnimi strategijami.
3. Implementacija globoke LSTM kot trgovalne strategije na primeru dnevnega razpršenega borznega mehanskega trgovanja.
4. Implementacija SNN kot trgovalne strategije na primeru dnevnega razpršenega borznega mehanskega trgovanja.
5. Nov pristop kodiranja vhodnih borznih in finančnih podatkov (generiranja učnega vzorca) za SNN.
6. Nov pristop učenja SNN.
7. Implementacija SNN kot trgovalne strategije MTS na FPGA.

## 1.5 Predpostavke in omejitve

V disertaciji privzamemo sledeče predpostavke/omejitve:

1. Zaradi prosto dostopnih podatkov na največ dnevni osnovi se omejimo na dnevno trgovanje. Podatke pridobimo s spletne strani Yahoo Finance<sup>2</sup>. Pri tem se omejimo na leta od junija 2009 do junija 2020. S tem se omejimo na obdobje po letih 2007–2009, ko je pustošila globalna finančna kriza, kar bi lahko negativno vplivalo na modele nevronske mreže. Predpostavljamo, da je izbrano obdobje dovolj reprezentativno, da lahko na njegovi osnovi sklepamo o uporabnosti vseh uporabljenih trgovalnih strategij.
2. Omejimo se na nemški delniški (borzni) trg, saj predpostavljamo, da je ta med najbolj likvidnimi v Evropi. Predpostavljamo, da je nemški delniški trg dovolj reprezentativen, da bi izsledke lahko prenesli tudi na druge, podobne delniške trge.
3. Predpostavljamo, da lahko dejansko dogajanje na borzi dobro predstavimo z naborom borznih/finančnih podatkov ter razširjenih indikatorjev. Zaradi dnevne frekvence podatkov predpostavljamo, da so zaključni tečaji, na osnovi katerih trgujemo, dostopne tik pred zaprtjem borze – ravno toliko, da lahko izvršimo želene menjave. Pri tem se seveda omejimo na simuliranje trgovanja (ne trgujemo s pravim denarjem).
4. Predpostavljamo, da bo večina doktorske disertacije implementirana s programsko kodo, nastala pa bo tudi namenska strojna oprema za MTS s FPGA. Predpostavljamo, da je vse trgovalne strategije s pomočjo knjižnic moč implementirati v programskem jeziku Python. Predpostavljamo, da je s portala Yahoo Finance moč pridobiti vse zahtevane borzne/finančne podatke, in da so ti resnični in popolni (ne vsebujejo manjkajočih vrednosti).
5. Predpostavljamo, da so izbrane trgovalne strategije uporabne, tj. sposobne zaznati špekulativne priložnosti na borzi, in sposobne s preudarnim trgovanjem delnic ustvariti prekomerni donos, tj. donos, večji od pasivne strategije. Predpostavljamo tudi, da večrazredno napovedovanje trgovalnih signalov (3-razredno, tj. kupi, prodaj ali zadrži) trgovalnim strategijam ne predstavlja težav.
6. Za trgovalni strategiji na osnovi nevronske mreže (LSTM in SNN) predpostavljamo, da se te v procesu učenja (modeliranja) prekomerno/preslabo (Brownlee, 2016) ne priležejo problemu (angl. overfitting/underfitting). »Pravo« rešitev bomo zaradi sporadičnosti (angl. stochastic) nevronske mreže in heurističnega postopka učenja poiskali eksperimentalno (s poskušanjem). Posledično predpostavljamo tudi, da bomo tako dosegli ponovljivo učenje oz. ponovljive rezultate.
7. Predpostavljamo, da bo sprotno posodabljanje izboljšalo ažuriranost modela in posledično zagotovilo bolj uporabne trgovalne signale.
8. Predpostavljamo, da so borzni in finančni podatki dovolj uravnoteženi (angl. balanced data), da lahko trgovalni strategiji na osnovi LSTM/SNN učinkovito zgradita model in slednjega uporabita za trgovanje. V praksi namreč večino učnih signalov predpostavlja signal zadrži, medtem ko sta kupi in prodaj v manjšini.
9. Pri trgovanju (kupovanju, prodajanju) predpostavljamo relativne, 1 % transakcijske stroške (Shin & Sohn, 2004; Šonje et al., 2014; Jar-long Wang & Chan, 2009; Weber, 2003). Predpostavljamo, da se pri trgovanju vedno kupi maksimalno število delnic,

---

<sup>2</sup> <https://finance.yahoo.com/>

zmanjšanih za transakcijske stroške (tako da ostane minimalno prostih denarnih sredstev) in da se vedno proda vse delnice, končni izkupiček pa je znova zmanjšan za transakcijske stroške.

10. Pri analizi se omejujemo na kapitalske dobičke in izgube, izplačila dividend pa zaradi podobnosti med trgovalnimi strategijami in zapletenega sistema pripoznavanja zanemarimo. Predpostavimo, da je trg popolnoma likviden, kar pomeni, da se odločitve trgovalne strategije realizirajo takoj, po aktualnem tečaju.

## 1.6 Metode raziskovanja

Metode raziskovanja razdelimo v tri sklope:

1. Eksperiment: pridobivanje zbirke podatkov in implementacija MTS; razširjanje zbirke podatkov z raznoraznimi tehničnimi indikatorji; delitev zbirke podatkov na dva vzorca: učnega (angl. in-sample) ter testnega (angl. out-of-sample).
2. Eksperiment: implementacija pasivne in klasičnih trgovalnih strategij ter trgovalne strategije na osnovi samo posodablajoče se LSTM; uporaba prosto dostopnih knjižnic programskega jezika Python, npr. Keras, Scikit-learn, Tensorflow, Pandas, Numpy, Matplotlib; napovedovanje na osnovi testnega vzorca; vizualizacija in komentiranje rezultatov; preizkušanje različnih parametrov/nastavitev mrež LSTM; poročanje ugotovitev.
3. Eksperiment: implementacija SNN nevronske mreže ter novih pristopov učenja kodiranja vhodnih podatkov; implementacija SNN in pripadajočega MTS na namenski strojni opremi – FPGA; vizualizacija in komentiranje rezultatov; preizkušanje različnih parametrov/nastavitev mrež LSTM; poročanje ugotovitev.



## 2 TEORETIČNI PREGLED

Poglavje je sestavljeno iz šestih podpoglavij. V prvem podpoglavju je zajet teoretični opis hipoteze učinkovitih trgov. Namen prvega podpoglavja je predstaviti tri različne oblike učinkovitosti trgov, poiskati razloge za in proti aktivnemu trgovanju na finančnih trgih ter poudariti neučinkovitosti, ki se pojavljajo na finančnih trgih. Drugo poglavje predstavlja model učinkovitega portfelja. Namen podpoglavja je predstaviti pojav korelacije med dvema ali več finančnimi instrumenti ter opisati nasprotovanja med vseskozi uporabno trostopenjsko fundamentalno analizo ter tehnično analizo, obe namenjeni za izbiro finančnih instrumentov v portfelj. Skupek finančnih instrumentov, zbranih v portfelju, zaradi pojava korelacije namreč izraža drugačne zakonitosti od posamičnega finančnega instrumenta, pri tem je zato ključnega pomena izbira najustreznejših posamičnih finančnih instrumentov, ki skupno zagotavljajo najugodnejši kvocient med donosnostjo in tveganjem. Tretje podpoglavje predstavlja podjetja nemškega delniškega trga, ki jih obravnavamo v analizi, pripeta sta tudi deskriptivna statistika delniških instrumentov in metodologija izračuna Hurstovega eksponenta. Četrto podpoglavje zajema postopek sestave in priprave zbirke podatkov. Obravnavamo šest različnih finančnih spremenljivk, ki jih pridobimo s finančnega portala Yahoo Finance. Namen poglavja je predstaviti in na primeru dobre prakse pokazati kakšnega tipa so vhodni in kakšnega tipa izhodni podatki. Dodatno so prikazane matematične enačbe za izračun zajetih tehničnih indikatorjev. Peto podpoglavje teoretično opisuje borzna dogajanja in gonilnike, ki so delovali v letih od 2007 do 2020. Namen podpoglavja je predstaviti skupne (enotne) finančne gonilnike, ki so v podobni meri učinkovali na vse zajete delniške instrumente. Pri tem smo osredotočeni na temeljne makroekonomske finančne indikatorje. Prav tako je dodana analiza podobnosti s preostalimi svetovnimi finančnimi trgi, kot npr. ameriškim, japonskim, kitajskim ter vsesplošno evropskim. Končno je predstavljen tudi makroekonomski odtis Nemčije v opazovanem obdobju. Zadnje, šesto poglavje predstavlja predlagano rešitev izziva. Namen podpoglavja je predstaviti pregled literature in dosedanje delo raziskovalcev na tem področju ter izpostaviti kako se predlagana rešitev od teh razlikuje. Dodatno je namen tega podpoglavja opisati naše preteklo delo na tem področju in predstaviti kakšne prednosti oz. novosti nudi naša rešitev v primerjavi z ostalimi.

### 2.1 Hipoteza učinkovitih trgov

Fama (1970) je v začetku sedemdesetih let prejšnjega stoletja formaliziral eno najpomembnejših hipotez na področju trgovanja in menjav na finančnih trgih – hipotezo učinkovitega trga (angl. Efficient Market Hypothesis, krajše EMH), pri čemer se po Malkiel (2003) učinkovitost nanaša na sposobnost »vpijanja« informacij, ne pa na npr. učinkovitost produkcijskih tvorcev. Tisti tržni mehanizem, kot piše Fama, ki vedno zagotavlja, da tečajne vrednosti finančnih instrumentov odsevajo popolnoma vse razpoložljive informacije, je učinkovit (angl. efficient).

Iz prakse vemo, da tečajne vrednosti finančnih instrumentov (npr. delnic) na učinkovitih trgih sledijo toku informacij – pozitivne informacije glede na pričakovanja stimulirajo povpraševanje in posledično pozitivno vplivajo na gibanje tečajev, kar povišuje njihov tečaj; in obratno. Glede na to, da se tovrstne informacije pojavljajo sporadično/stohastično/naključno, je naključna tudi tečajna vrednost finančnih instrumentov. In če je tečajna vrednost naključna, potem je uporaba sistematičnih metod trgovanja in napovedovanja (npr. tehnična analiza) na goli

osnovi preteklih podatkov zaman (bolje rečeno ne zagotavlja presežnega zaslужka). Če je torej določen finančni trg učinkovit, potem si vlagatelji izključno zaradi modernih tehnik trgovanja ne morejo obetati višjega donosa, ampak morajo ob tem nepreklicno sprejeti tudi višjo stopnjo tveganja.

Fama (1970) je v originalnem delu obravnaval tri oblike učinkovitosti trgov: šibko, pol-močno in močno. Glede šibke oblike učinkovitosti trgov je dejal, da tečajne vrednosti odsevajo popolnoma vse možne tržne informacije, ki so na voljo, npr. tečajne vrednosti in obseg trgovanja (angl. volume), kar pomeni, da trgovanje s strategijami izključno iz preteklih tečajnih vrednosti ne prinaša presežnih donosov. Pol-močno obliko učinkovitosti je Fama interpretiral kot obliko, pri kateri tečajne vrednosti odsevajo vse javne informacije, ki so na voljo. Javne informacije so širšega nabora, saj poleg vseh tržnih informacij dodatno k tem zajemajo še objave podjetij, gospodarskih nihanj in novic ter političnih dogajanj (Madura, 2012). Velja, da je pol-močna oblika učinkovitosti podmnožica šibke, kar za dan trg pomeni, da ob veljavnosti pol-močne oblike avtomatsko velja tudi šibka. Močna oblika učinkovitosti poleg vseh tržnih in javnih informacij dodatno vključuje tudi notranje (nejavne) informacije (torej, če velja močna oblika, avtomatsko velja tudi pol-močna). Notranje informacije omogočajo določenemu ozkemu naboru posameznikov strateško (nepravično) prednost, kar lahko ob izkoriščanju vodi v tržne neučinkovitosti; zato je izkoriščanje notranjih informacij za lasten zaslužek zakonsko prepovedano.

V preteklosti se je uveljavilo veliko raziskav na temo preverjanja hipoteze učinkovitih trgov. Damodaran (2002) kot dve najpogostejši tehniki preverjanja EMH navaja študijo dogodkov (angl. event study) in študijo portfelja (angl. portfolio study; podobno slednji smo uporabili v tej doktorski disertaciji, a ne za testiranje EMH, temveč za preizkušanje ITS). Prav tako se Damodaran strinja, da če surovi podatki kotiranj delnic podjetij izkazujejo kratkoročne ali dolgoročne avtokorelacijske vzorce, da lahko ti vzorci nakazujejo na možno napovedovanje gibanja tečaja v prihodnost. Študije, kot npr.: (Borges, 2010; Chan et al., 1997; Jensen, 1978; Lai & Lai, 1991; Perron & Phillips, 1988), niso ugotovile večjih odstopanj od učinkovitosti in posledično na osnovi vzorčnih niso zavrnilo veljavnosti EMH. Po drugi strani so v preteklosti številni borzni gurugi, kot pišeta Strašek & Jagrič (2008), dokazali, da je s premetenim trgovanjem moč doseči izjemne presežne in špekulativne donose. Jensen (1978) je nanizal celo paleto raziskovalnih del, ki so dokazala morebitne neučinkovitosti na določenih trgih, s tem pa tudi možnosti za doseganje prekomernih zaslužkov. Tovrstne neučinkovitosti so nakazale na obstoj anomalij in nekonsistentnosti na trgih, kar je podrobneje opisal Bator (1958), te pa lahko vodijo tudi do trajnejših posledic na trgih, npr. propadov trgov (angl. market failure). Med njimi med najvplivnejše uvrščamo obstoj javnih dobrin, nepopolno konkurenco, nepopolnost informacij (informacijska asimetrija) in negotovost. Shiller (2003) in Barnes (2016) k temu dodatno prištevata tudi čredni nagon (angl. herd instinct), ki se je v preteklosti že velikokrat izrazil v obliki špekulacij, balončkov, manij, panik in propadov. Številne študije (npr. Atsalakis & Valavanis, 2009; Y. P. Chung, 1991; D. Fister, Mun, idr., 2019; Hamid idr., 2017; Jagrič idr., 2005; Lee idr., 2010; Lo & MacKinlay, 2014) so empirično pokazale, da je s proaktivnim trgovanjem na osnovi kompleksnih trgovalnih algoritmov moč doseči presežne donose. Študije (Cervelló-Royo et al., 2015; Hsu et al., 2016; Kwon & Kish, 2002; Lukac et al., 1988; Narayan et al., 2015; Taylor, 2014; F. Wang et al., 2014) so pokazale, da so lahko donosne celo klasične (enostavne) trgovalne strategije.

Pod klasične trgovalne strategije prištevamo raznorazne tehnične indikatorje (tehnične analize), ki jih je moč izpeljati neposredno iz borznih podatkov (npr. na osnovi tečaja ob zaprtju borze, angl. close prices). Avtorji so v omenjenih študijah pokazali možnosti zaslužkov tako na kapitalskih trgih, menjalnih tečajih, kakor tudi na terminskih trgih s surovinami. Nekateri avtorji gredo korak naprej in se poslužujejo napovedovanja tečaja delnic, delniških indeksov in cen energentov. Ta »regresijski« princip se pomembno razlikuje od »klasifikacijskega«, saj pri tem sistem namesto sprejemanja splošnih odločitev o nakupu, prodaji ali držanju instrumentov, napoveduje prihajajoče cene. Napovedovanje cen je v splošnem bistveno zahtevnejše (v širši praksi sta uporabna oba), a v smislu mehanskega trgovanja ne prinaša dodane vrednosti, saj je treba napoved cen v naslednjem koraku prav tako pretvoriti v trgovalni signal. Študije (Al-Hnaity & Abbod, 2015; Chen, 2014; Dreger & Wolters, 2014; Ghalayini, 2013; Gupta & Dhingra, 2012; P. Li et al., 2017; Mondal et al., 2014; Pettenuzzo et al., 2014; Rapach & Zhou, 2013; J. Z. Wang et al., 2011; Jie Wang & Wang, 2015) opisujejo napovedovanje tečajev, med drugim napovedovanje tečajev delnic, indeksov, menjalnih tečajev, povpraševanje po denarju in cenah elektrike, ipd. Med metodami napovedovanja so dandanes med najpopularnejšimi nevronske mreže (usmerjene ali časovne, angl. feedforward, recurrent), skriti modeli Markova (angl. Markov hidden chains) in odločitvena drevesa (angl. decision trees). Med klasičnimi metodami prevladujejo metoda glavnih komponent (angl. Principal Component Analysis, krajše PCA), ARIMA (angl. Autoregressive Integrated Moving Average) in ostale. Sklepamo, da razvoj tovrstnih algoritmov in modelov ne bi bil tako razgiban, če bi na vseh trgih veljala EMH.

Damodaran (2002) učinkovitosti trga namenja veliko pozornost, saj opozarja, da je informacija o učinkovitosti trgov ključna za vlagatelje. V kolikor velja, da je trg učinkovit, pomeni, da je dejanski tržni tečaj delnice najboljši približek dejanske vrednosti; nasprotno velja, da tržni tečaj več ali manj odstopa od prave vrednosti, zato pa naj vlagatelj uporabi postopke vrednotenja delnic, da alternativno izračuna predvideno vrednost. Vlagatelji, ki točneje izračunajo predvideno vrednost, bodo posledično nagrajeni z višjimi tržnimi donosi, in obratno. Damodaran torej za razliko od Fame pravi, da je učinkovit trg tisti, kjer so tržni tečaji instrumentov nepristranske ocene dejanskih (pravih) vrednosti. Nadalje Damodaran (2002) piše, da:

- učinkovitost trga ne zahteva vseskožno enakost tržnih in pravih cen, temveč le nepristranskost (naključnost) odstopanj med njimi;
- če so odstopanja naključna, pomeni, da sta verjetnosti podcenjenosti ali precenjenosti delnic enaki in da so odstopanja nekorelirana s katerim koli primerkom;
- če so odstopanja tržnega in pravega tečaja naključna, pomeni, da nobena skupina vlagateljev ne more poiskati podcenjenih ali precenjenih delnic (s katero koli trgovalno strategijo).

Ob nadaljnjem razmišljanju Damodaran sklene, da je učinkovitost trga vedno določena glede na določeno skupino vlagateljev, najvidnejšo vlogo pri tem pa igrajo različne stopnje obdavčevanja med vlagatelji ter obravnava transakcijskih stroškov. Dodatno avtor implicira, da na močno učinkovitem trgu noben vlagatelj ne zmore poiskati podcenjenih delnic in da:

- vrednotenje podjetij ni smiselno, saj so verjetnosti za iskanje podcenjene delnice naključne in enake 50-50;

- bo naključno razprševanje delnic brez smiselne celote in informacij zagotavljalo enak uspeh kot proaktivno menedžeriranje portfelja (kar je slabo, saj proaktivni menedžment prinaša dodatne stroške);
- bo strategija, ki bo najmanj frekventna, v prednosti pred bolj frekventnimi.

## 2.2 Učinkovit portfelj


Vlagatelj na finančnem trgu je stalno pred dilemo, s katerimi finančnimi instrumenti sploh trgovati. To vprašanje je bilo v preteklosti že dodobra pretreseno, največ pozornosti pa je požel Harry Markowitz, utemeljitelj t. i. moderne teorije portfelja (angl. Modern Portfolio Theory, krajše MPT) in učinkovitega portfelja (angl. efficient portfolio, H. Markowitz, 1952). Namen teorije MPT je iz končnega nabora potencialnih delnic izbrati določeno število delnic (izbor poimenujemo portfelj), pri čemer bo ta portfelj učinkovit. Markowitz vsako delnico opiše z dvema lastnostma, srednjo vrednostjo  $E$ , s katero simbolizira povprečni pričakovani donos (po verjetnostni teoriji), in varianco  $V$ , s katero simbolizira tveganje (nestanovitnost):

$$MPT = \frac{\text{povprečni pričakovani donos } (E)}{\text{varianca } (V)}$$

Par obeh vrednosti  $EV$  Markowitz izriše v koordinatni sistem, s pomočjo katerega določi delnice z optimalnim kompromisom med tveganjem in povprečno pričakovano vrednostjo (H. M. Markowitz, 1987).

Slika 1 prikazuje postopek splošnega modela izbire portfelja z enostavnim mehanizmom povprečne pričakovane vrednosti in variance posameznih delnic. Velja, da je kombinacija  $EV$  neučinkovita, v kolikor obstaja drugačna kombinacija  $EV$ , ki zagotavlja ali (1) manjšo varianco  $V$  ob vsaj enaki vrednosti povprečne pričakovane vrednosti  $E$ , (2) večjo povprečno pričakovano vrednost  $E$  ob vsaj enaki varianci  $V$ , (3) tako večjo povprečno pričakovano vrednost  $E$  in hkrati manjšo varianco  $V$ .

Slika 1: Markowitzeva učinkovita fronta



Opombe: Črne pike predstavljajo posamične kombinacije  $EV$ , pri čemer je število črnih pik enako številu potencialnih delnic za izbiro optimalnega portfelja. Črke  $a, b, c, d$  označujejo štiri različne režime. Vir: (H. M. Markowitz, 1987).

Markowitz je ugotovil, da lahko za kombinacije  $EV$  znotraj omejitev črtkane črte najdemo boljše alternative, sodeč po povprečni pričakovani vrednosti in varianco, kar inherentno pomeni, da se najboljše, od tod pa tudi optimalne kombinacije  $EV$  nahajajo na parabolični

fronti, ki jo ponazarja polna črta (med črkama  $b$  in  $c$ ). Tako fronto imenujemo učinkovita fronta (angl. efficient frontier), portfelj z zbranimi podjetji, ki se nahajajo na fronti, pa učinkovit portfelj. Za slednjega velja, da za vsako kombinacijo  $EV$  ne moremo najti alternativne kombinacije  $EV$ , ki bi zagotavljala ali (1) manjšo varianco  $V$  ob vsaj enaki vrednosti povprečne pričakovane vrednosti  $E$  ( $h \rightarrow k$ ), (2) večjo povprečno pričakovano vrednost  $E$  ob vsaj enaki varianci  $V$  ( $h \rightarrow j$ ), (3) tako večjo povprečno pričakovano vrednost  $E$  in hkrati manjšo varianco  $V$  ( $h \rightarrow i$ ).

Splošna teorija MTP se je kot temeljno delo izbire optimalnega portfelja iz nabora delnic ohranila do danes. Seveda obstajajo različne variacije izbire optimalnega portfelja, npr. Tobin-Sharpe-Lintner model ali Blackov model, razvile so se tudi modernejšie metodologije, npr. optimizacijski algoritmi (Almahdi & Yang, 2019) ali kombinatorična optimizacija (Y. Peng et al., 2021), ki lahko upoštevajo veliko več kot le dve lastnosti, npr. povprečno pričakovano vrednost  $E$  in varianco  $V$ .

Hagströmer & Binner (2009) sta predstavila alternativno izbiro optimalnega portfelja. Na množici 97 delnic sta avtorja uporabila optimizacijski algoritem DE in pri tem ugotovila, da njuna implementacija izboljša portfeljski donos v primerjavi s portfeljem  $EV$ . Tudi Hok & Zuhail (2010) sta za problem alokacije delnic portfelja uporabila optimizacijski algoritem, tj. genetski algoritem, pri čemer avtorja ocenitveno funkcijo definirata kot kvocient funkcije donosa in funkcije tveganja:

$$ff = \frac{f(\text{donos})}{f(\text{tveganje})} = \frac{\sum_{i=0}^N r_i \cdot w_i}{\sum_{i=0}^N \sum_{j=0}^N w_i \cdot w_j \cdot \sigma_{ij}}$$

$N$  predstavlja celotno število delnic,  $w_i$  pa uteži oz. deleže, kapitalizacije posameznih delnic glede na celotno kapitalizacijo vseh delnic ( $\sum_{i=0}^N w_i = 1$ ). Nadalje predstavlja  $r_i$  povprečni pričakovani donos delnice, dodatno lahko določimo tudi povprečni pričakovani donos portfelja kot  $r_W = \sum_{i=0}^N r_i \cdot w_i$ . Končno predstavlja  $\sigma_{ij}$  mero tveganja, standardni odklon delnice, pri čemer se zapisano za celotni portfelj razširi v  $\sum_{i=0}^N \sum_{j=0}^N w_i \cdot w_j \cdot \sigma_{ij}$ , kjer je  $\sigma_{ii} = \sigma_i^2$  varianca delnice  $i$ ,  $\sigma_{ij}$  pa kovarianca delnic  $i$  in  $j$ .

Prednost držanja več delnic hkrati v primerjavi z držanjem ene delnice imenujemo razpršitev (angl. diversification). Matematično namreč lahko pokažemo, da se tveganje zaradi vpeljave  $t$ . i. korelacije med delnicami zmanjša, če vlagatelj drži več kot eno delnico. Dodatno lahko pokažemo, da če vlagatelj v portfelju drži številne delnice, pade tveganje na  $t$ . i. sistematično raven oz. se raven nesistematičnega tveganja zmanjša na praktično nič. Del  $\sum_{i=0}^N \sum_{j=0}^N w_i \cdot w_j \cdot \sigma_{ij}$  lahko namreč razbijemo kot:

$$\sigma_p^2 = \sum_{i=0}^N w_i \cdot \sigma_i^2 + \sum_{i=0}^N \sum_{j \neq i}^N w_i \cdot w_j \cdot \sigma_i \cdot \sigma_j \cdot \rho_{ij},$$

pri čemer z  $\rho_{ij}$  opišemo vrednost korelacije med delnicama  $i$  in  $j$ . Korelacija  $\rho_{ij}$  je določena v rangu  $-1 \leq \rho_{ij} \leq 1$ , v kolikor ta ne znaša  $\rho_{ij} = 1$  (kar je v praksi zelo pogosto), potem ugotovimo, da pride po zmanjšanju skupnega portfeljskega tveganja  $\sigma_p^2$ . Naš cilj je potemtakem držati čim večje število delnic, ob tem pa paziti, da so te skrbno medsebojno izbrane. Kljub temu se moramo zavedati, da tveganja ne moremo izničiti in da bo določen del

(sistematičnega) tveganja ostal tudi po razprševanju delnic, z drugimi besedami – tudi če bi po tem nadalje razprševali delnice, se tveganje portfelja ne bi bistveno zmanjšalo.

Hok & Zuhail (2010) na primeru azijskih delnic z uporabo zaključnih tečajev med leti 2004 in 2009 pokažeta, da je moč s tradicionalnim genetskim algoritmom implementirati optimizacijo portfelja. Freitas idr. (2009) izdelajo sistem napovedovanja optimalnega portfelja z uporabo ANN. Testiranja z različnimi metrikami (povprečna napaka, koren povprečne kvadrirane napake, povprečne absolutne napake in druge) med leti 2004 in 2007 na naboru 52 brazilskih delnic pokažejo, da je izbrani optimalni portfelj zmožen generirati višje donose tako od indeksa, kakor tudi od optimalnega portfelja po pristopu povprečne pričakovane vrednosti in variance (*EV*).

Tudi Damodaran (2002), starosta vrednotenja podjetij, se dotakne področja t. i. menedžmenta portfelja. Sam pravi, da je veliko od sestave portfelja odvisno od vlagateljeve filozofije. Vlagatelji, ki vlagajo na kratki čas, se manj posvečajo vrednotenju podjetij (njihove odločitve bazirajo na relativnih dognanjih), vlagatelji na dolgi rok po drugi strani po vrednotenju posegajo veliko več. Damodaran je predstavnik misli, ki pravi, da je objektivna številska analiza le del vlaganj in da je drugi del vlaganj zgodba. Potemtakem lahko potegnemo pomembno iztočnico, da je MPT teorija le objektivni del vlaganj, ki pa ni popoln, in ga je zato treba kombinirati z mehкими metodami.


Alternativno Damodaran predlaga vrednotenje po trojici fundamentalne analize, zajete v trikotniku tabele 1, po vzoru Straška & Jagriča (2008). Damodaran v primerjavi z MPT držanje portfelja vidi vsekakor širše (MPT upošteva le povprečno pričakovano vrednost ter varianco), saj zagovarja vrednotenje vsakega podjetja posebej, z eno izmed treh metod vrednotenja: (1) diskontiran denarnih tokov, (2) relativnega vrednotenja in (3) vrednotenje opcij. Po tovrstnem izbiranju delniških podjetij (angl. stock picking) bo vlagatelj v portfelj držal delnice, za katere bo prepričan, da mu bodo zagotovile najvišje neto sedanje vrednosti oz. bodo najbolj relativno situirane. Prav neučinkoviti trgi so izhodišče za uvrščanje najbolj podcenjenih delnic v vlagateljski portfelj.

Končno naj omenimo, da se v tej doktorski nalogi z izbiro osnovnega nabora delnic, iz katere sestavljamo portfelj ne ukvarjamo. Prav tako se ne ukvarjamo z izbiro enotnega optimalnega portfelja, ki nespremenjen na dolgi rok garantira najvišji presežni donos. Odločitev o osnovnem naboru delnic prepustimo borzi in trgujemo kar z delnicami uveljavljenega borznega indeksa, v kateri so delnice podjetij skrbno izbrane po velikosti in razpoznavnosti delniškega podjetja, njegovi tradiciji in dobrem finančnem poslovanju. V dotičnem primeru trgujemo z delnicami, ki kotirajo na nemški borzi znotraj nemškega najbolj znanega indeksa DAX30. Vsa delniška podjetja bodo predstavljena v nadaljevanju.

## **2.2.1 Ekonomska – sektorska – temeljna analiza**

Markowitzov učinkoviti portfelj je zelo uporabna metoda za določitev optimalne sestave portfelja finančnih instrumentov, a zaradi zanašanja na le dve posamezni spremenljivki ni edina. Strašek & Jagrič (2008) navajata trojico ekonomska – sektorska – temeljna analiza. Slednjo upodobimo v narobe obrnjenem trikotniku v tabeli 1.

Tabela 1: Ekonomska – sektorska – temeljna analiza



Vir: Strašek & Jagrič (2008)

Po pristopu »top-down« je vsaka naslednja analiza izmed trojice bolj koncentrirana. Ekonomska analiza podaja vsesplošni oz. makroekonomski odtis posamezne države, sektorska analiza podaja bolj koncentriran opis o dotičnem sektorju posamezne države, v katerega se spleča vlagati, temeljna analiza pa izpostavlja posamezna podjetja v posameznem sektorju posamezne države. Nabor delnic je z vsako naslednjo analizo nekoliko ožji, dokler ne dospemo do končnega produkta top-down pristopa, tj. portfelja. V praksi se je uveljavil tudi alternativni »bottom-up« pristop, ki izhaja iz točno določenih (želenih) podjetij, ki jih vlagatelj želi imeti v portfelju, in se sodeč po takem portfelju osredotoča predvsem na sektorski in makroekonomski odtis želenih podjetij.

Pri makroekonomski analizi gre predvsem za spremljanje cikličnega oz. acikličnega gibanja opazovanih spremenljivk (inflacije, realnega BDP, obrestnih mer, brezposelnosti) v poslovnem ciklu. Najpomembnejšo vlogo pri tem zagotovo nosijo t. i. vodilni indikatorji, ki z dano verjetnostjo napovedujejo bodočo gospodarsko aktivnost. Ekonomska analiza zaradi obravnavanja obrestnih mer išče vzporednice tudi na domačih in tujih obvezniških trgih, prav tako pa se dotika tudi surovinskih, deviznih ter terminskih trgov. Sektorska analiza se prične z determiniranjem življenjskega ciklusa sektorja in obsega pet zaporedno sledečih si faz. To so razvoj, rast, ekspanzija, zrelost in padec industrijskih sektorjev, pri čemer se mora vlagatelj odločiti, v sektorje katere faze bo vložil. Vlaganja v sektorje, ki so v fazah razvoja in rasti, so tvegana, saj vlagatelj nima zagotovila, da bo podjetje dejansko uspelo. Po drugi strani tovrstna vlaganja obetajo visok donos, a šele v prihodnosti, saj v začetku podjetja dividend navadno ne izplačujejo, posledično pa je vrednotenje tovrstnih sektorjev zahtevno. Sektorji, ki so v fazah ekspanzije in zrelosti, še vedno rastejo, a po zmanjšani stopnji rasti. Posledično taka podjetja redno izplačujejo dividende. V kolikor ne pride do prestrukturiranja, zadnja faza padca naznanja stagniranje in možni stečaj podjetij. V tej fazi potrošniški trg postane nasičen produktov oz. se pojavijo boljše alternative. Nekateri vlagatelji svoja vlaganja sektorsko rotirajo, kar pomeni, da se prilagajajo cikličnim nihanjem posameznih sektorjev.

Temeljna analiza se deli na dve teoriji, na klasično teorijo in teorijo zaupanja (Strašek & Jagrič, 2008). Zagovorniki klasične teorije prepoznavajo sedanjo vrednost bodočih dividend

(dobičkov) kot glavno merilo za oblikovanje tečaja po pošteni (absolutni oz. notranji) vrednosti. Po Damodaranu (2016) lahko vlagatelj podjetje oceni tudi relativno, a potrebuje pri tem primerljive konkurente. Največkrat se relativno primerjajo tržni multiplikatorji podjetij, npr. P/E (angl. price-to-earnings ratio, slov. razmerje med tečajem in dobičkom), P/Sales (angl. price-to-sales ratio, slov. razmerje med tečajem in prihodki od prodaje) ter P/EBIT (angl. price-to-EBIT ratio, slov. razmerje med tečajem delnice in dobičkom iz poslovanja).

### 2.2.2 Tehnična analiza

Za začetnika tehnične analize štejemo Charlesa Dowa, pod terminom Dowova teorija (Bishop, 1961; Nelson, 1903). Originalna Dowova teorija zajema šest bistvenih načel, ki so se skozi čas bolj ali manj oblikovala. Dandanes pod pojmom tehnična analiza poznamo:

»Tehnična analiza je študija aktivnosti na trgu, primarno skozi uporabo grafov, z namenom napovedovanja bodočih tečajnih trendov« je zapisal Murphy (1999), pri čemer je avtor pod aktivnosti vključil dve osnovni informaciji: tečaj in obseg trgovanja. Murphy zapiše tri močne predpostavke, pod katerimi temelji tehnična analiza:

1. *Trg diskontira vse*, kar pomeni, da kakršni koli dejavniki/spremenljivke, npr. ekonomski, monetarni, politični, vedenjski ali psihološki, vplivajo na tržni tečaj oz. povedano drugače, tečaj vsebuje vse te razpoložljive informacije; iz tega sledi, da je študija tečaja vse, kar vlagatelj potrebuje. Če je povpraševanje večje od ponudbe, bo tečaj rasel, in obratno, to je treba čimprej ugotoviti, razlog, zakaj je temu tako, pa ni potreben.
2. *Tečaji se gibljejo v trendih* in na plečih čartista (strokovnjaka, ki se ukvarja s tehnično analizo) je, da te trende čimprej odkrije; posledica trenda je, da se bo tečaj bolj verjetno gibal v smeri trenda naprej, kot pa obrnil proti trendu.
3. *Zgodovina se ponavlja*, s tem pa tudi pretekli psihološki vzorci, ki simbolizirajo ali bikovski ali medvedji trend; nekateri vzorci so bili ugotovljeni na podlagi več kot stoletja dolge tradicije trgovanja, zato je zelo verjetno, da se bodo ponavljali tudi v bodoče (človeška psihologija se na kratki rok namreč ne spreminja).

Murphy (1999) nadaljuje, da se za razliko od fundamentalistov, ki se v glavnem posvečajo teoriji ponudbe in povpraševanja za determiniranje notranjega tečaja, čartisti osredotočajo na dejanske aktivnosti na trgu. Fundamentalisti preučujejo vse možne vire informacij, medtem ko so te čartistom že na voljo v obliki tržnega tečaja. Fundamentalisti preučujejo vzroke oz. razloge, medtem ko čartisti učinke oz. efekte (praktično pa oboji stremijo k podobnemu cilju). Medtem ko fundamentaliste zanima razlog, zakaj je temu tako, pa čartiste zanima le, kakšen bo učinek tega. Politika dividend je fundamentalistom eden najpomembnejših virov za diskontiranje prihodnjih tokov, čartistov pa to sploh ne zanima. Fundamentalisti so bolj srednjeročno in dolgoročno usmerjeni, medtem ko čartisti izredno kratkoročno (slednji zaradi hitrih reakcij velikokrat uporabljajo celo avtomatizirane programske rutine). V praksi prihaja do kombiniranja prednosti obeh metod, saj fundamentalna analiza dobro pove, kakšno kombinacijo finančnih instrumentov izbrati, medtem ko tehnična analiza pove, kdaj tempirati aktivnosti. Murphy (1999) zaključuje, da tehnična analiza posredno zajema tudi fundamentalno.

Praktično je tehnična analiza realno-časovno spremljanje trgov in aktivnosti na trgih. Čartist poskuša s kopico matematičnih postopkov vizualiziranja, filtriranja, povprečenja, interpoliranja ipd. na dotičnem trendu napovedati, kaj se bo zgodilo v prihodnosti in v pravem



trenutku zavzeti pripadajoče pozicije na trgu, tako da bo iz tega maksimalno iztržil. Zaradi fleksibilnosti tehnične analize se da slednja enostavno in z majhnimi stroški avtomatizirati, npr. z globokimi nevronskimi mrežami. Tako ni več človek tisti, ki vrši tehnično analizo in v tržnih serijah ugotavlja ponavljajoče se vzorce, temveč računalnik.

## 2.3 Zajeta podjetja

V okviru doktorske disertacije smo se osredotočili na nemška podjetja, ki kotirajo znotraj nemškega kapitalizacijsko-tehtanega »blue-chip« indeksa DAX30. Naj omenimo, da je bil indeks DAX30 v letu 2020, ko je ta raziskava potekala, predmet številnih menjav in da je nabor podjetij, ki smo jih zbrali iz spletne strani Finanzen.net<sup>3</sup>, bil določen 12. maja 2020, kmalu po tem pa se je ta nabor zaradi pandemične krize dodobra spremenil. Tabela 2 prikazuje seznam podjetij, zajetih v raziskavo.

Tabela 2: Seznam podjetij, pridobljen s spletne strani Finanzen.net v maju 2020, ki smo jih obravnavali v raziskavi

Podjetje	Kratica	Beta	TK	min	max	povp	JB	DF
Adidas AG	ADS.DE	0,88	51,83	35,01	316,05	116,79	1.015,43	0
Allianz SE	ALV.DE	1,10	80,48	57,47	232,00	138,11	413,81	0
BASF SE	BAS.DE	1,26	52,75	39,03	97,67	69,35	644,01	0
Bayer AG	BAYN.DE	1,29	64,99	36,23	143,88	81,38	424,32	0
Beiersdorf AG	BEI.DE	0,17	22,47	39,35	116,35	73,39	395,75	0
Bayerische Motoren Werke AG	BMW.DE	1,37	38,43	28,65	122,60	73,29	1.142,10	0
Continental AG	CON.DE	1,66	19,86	32,13	251,30	135,18	286,37	0
Covestro AG*	1COV.DE	1,41	6,88	n/a	n/a	n/a	n/a	n/a
Daimler AG	DAI.DE	1,68	42,61	21,84	95,79	55,47	658,73	0
Deutsche Borse AG	DB1.DE	0,36	28,57	36,13	157,20	75,13	1.039,76	0
Deutsche Bank AG	DBK.DE	1,63	17,98	4,87	46,90	21,59	418,91	0
Deutsche Post AG	DPW.DE	1,29	39,15	9,13	40,99	23,70	417,79	0
Deutsche Telekom AG	DTE.DE	0,59	72,14	7,71	18,05	12,69	259,05	0
E.ON SE	EOAN.DE	0,87	26,20	6,03	26,61	12,34	1.794,42	1
Fresenius Medical Care AG & CO. KGaA	FME.DE	1,12	22,94	36,10	93,00	63,17	321,07	0
Fresenius SE & CO. KGaA	FRE.DE	0,93	29,82	13,93	79,65	44,31	310,49	0
Heidelberg Cement AG	HEI.DE	1,39	10,36	24,57	95,50	60,22	456,54	0
Henkel AG & Co. KGaA	HEN3.DE	0,58	35,03	35,21	128,90	81,85	396,51	0
Infineon Technologies AG	IFX.DE	1,42	26,95	3,77	25,49	11,92	513,43	0

<sup>3</sup> <https://www.finanzen.net/>

Podjetje	Kratika	Beta	TK	min	max	povp	JB	DF
Deutsche Lufthansa AG	LHA.DE	1,22	4,50	7,18	31,12	15,19	2.443,49	0
Linde plc	LIN.DE	0,73	116,21	75,96	208,60	96,35	3.009,16	0
MERCK KGaA	MRK.DE	0,69	45,78	28,41	125,60	70,90	318,83	0
MTU AERO engines AG	MTX.F	n/a	9,29	35,25	286,40	100,51	2.218,86	0
Munchener Ruckversicherungs-Gesellschaft AG	MUV2.DE	0,76	33,95	79,55	282,60	158,76	966,62	0
RWE AG	RWE.DE	1,11	18,69	9,20	68,73	27,48	2.667,97	1
SAP SE	SAP.DE	1,07	144,60	31,11	129,44	69,30	615,22	0
Siemens AG	SIE.DE	1,23	88,22	59,76	133,20	92,72	577,96	0
Volkswagen AG	VOW3.DE	1,72	77,90	55,50	255,20	145,20	1.129,20	0
Vonovia SE*	VNA.DE	0,41	29,73	n/a	n/a	n/a	n/a	n/a
Wirecard AG*	WDI.DE	0,47	11,85	n/a	n/a	n/a	n/a	n/a

Opombe »\*«=podjetja niso zajeta v raziskavo, saj podatki o tečajih niso dostopni za celotno opazovano obdobje. »TK« predstavlja tržno kapitalizacijo, ta je podana v milijardah EUR. Tržno kapitalizacijo in pripadajočo beto smo pridobili s spletne strani Yahoo Finance dne 6. junija 2020. Dodana je tudi osnovna deskriptivna statistika tečajev delnic (podanih v EUR): najnižja »min«, najvišja »max«, srednja vrednost »povp«, Jarque-Bera statistika »JB« in rezultati augmentiranega Dickey-Fuller preizkusa stacionarnosti »DF«. Visoke vrednosti statistike JB (na zaključnih tečajih) pričajo o nenormalni porazdelitvi spremenljivk, medtem ko rezultati preizkusa stacionarnosti ADF kažejo, da sta le dve seriji zaključnih tečajev podjetij EOAN.DE in RWE.DE stacionarni. Iz tega sklepamo, da je klasična regresijska analiza popolnoma neprimerna. Vir podatkov: D. Fister idr. (2021).

V doktorskem delu je zajetih 27 različnih nemških delniških podjetij, za katere so pridobljeni podatki o finančnih kotacijah. Iz tega je sestavljena zbirka podatkov finančnih kotacij in izračunana izhodna (odvisna) spremenljivka. Gre za uspešna podjetja, večina izmed njih je svetovno znanih. Naslednje podpoglavje opisuje postopek pridobivanja zbirke podatkov finančnih kotacij in širjenja zbirke s tehničnimi indikatorji, z namenom preizkušanja ITS za avtomatizirano trgovanje.

## 2.4 Zbirka podatkov finančnih kotacij

Originalno zbirko podatkov finančnih kotacij (X) smo pridobili s spletne strani Yahoo Finance<sup>4</sup>, ta je sestavljena iz naslednjih prosto dostopnih elementov na dnevni osnovi:

- začetni (angl. open), najvišji (angl. high), najnižji (angl. low), zaključni (angl. close), prilagojeni zaključni (angl. adjusted close) tečaj in
- obseg menjav (angl. volume).

V tabeli 3 je prikazan primer zbirke podatkov finančnih kotacij za delnico Lufthansa v štiridnevem obdobju. Omeniti velja, da se vrednosti vseh tečajev in obsega menjav nanašajo na dnevno poslovanje, npr. najvišji tečaj je določen z najvišjim tečajem dotičnega dne v času odprtja borze.

<sup>4</sup> <https://finance.yahoo.com/>

Tabela 3: Primer zbirke podatkov za nemško delnico Lufthansa v času od 2. januarja 2019 do 7. januarja 2019

Datum	Začetna	Najvišja	Najnižja	Zaključna	Prilagojena	Obseg
...	...	...	...	...	...	...
Jan 02, 2019	19,93	20,05	19,59	19,77	19	3.190.464
Jan 03, 2019	19,68	20,09	19,19	19,26	18,5	3.972.099
Jan 04, 2019	19,47	19,82	19,37	19,78	19	3.272.227
Jan 07, 2019	19,97	20,09	19,67	19,82	19,04	2.860.506
...	...	...	...	...	...	...

Vir podatkov: Yahoo Finance

Originalna zbirka  $X$  ( $2773 \times 6$ ) je zajemala 27 podjetij v časovnem obdobju od 1. junija 2009 do 12. maja 2020. Slednjo smo v naslednjem koraku razširili s tehničnimi indikatorji z namenom povišanja informacijske vrednosti zbirke podatkov kotacij. Tako smo tvorili razširjeno zbirko, ki smo jo označili z  $X'$  ( $2623 \times 43$ ). Razširjena zbirka je zajemala časovno obdobje od 4. januarja 2010 do 12. maja 2020; slednjo smo skrajšali po časovnem obdobju zaradi lastnosti nekaterih tehničnih indikatorjev, katerih vrednosti za določeno začetno (angl. blackout) periodo ne morejo biti določene (tak primer so npr.  $n$ -dnevni donosi ali eksponentno povprečje zadnjih  $n$ -dni). Razširjena zbirka  $X'$  je bila sestavljena iz vsebine originalne zbirke  $X$ , razširjene z borznimi in tehničnimi indikatorji, prikazanimi v tabeli 4.

Tabela 4: Skupina pojasnjevalnih spremenljivk, pojasnjevalne spremenljivke in število pojasnjevalnih spremenljivk v določeni skupini in skupno

Skupina pojasnjevalnih spremenljivk	Pojasnjevalne spremenljivke	Št. spremenljivk
1. Tržni podatki (DAX30 indeks)	začetni tečaj (dena) delnice	6
	zaključni tečaj (dena) delnice	
	najvišji tečaj (cena) delnice	
	najnižji tečaj (cena) delnice	
	prilagojen zaključni tečaj (cena) delnice	
	obseg menjav	
2. Delniški podatki	začetni tečaj (dena) delnice	6
	zaključni tečaj (dena) delnice	
	najvišji tečaj (cena) delnice	
	najnižji tečaj (cena) delnice	
	prilagojen zaključni tečaj (cena) delnice	
	obseg menjav	
3. Časovni podatki	mesec	5
	dan	
	dan v tednu	
	št. dni do naslednjega trgovalnega dne	
	št. dni od zadnjega trgovalnega dne	
4. Tehnični indikatorji	RET: $n = \{1,2,3,\dots,10\}$ -dnevna perioda	10
	DIFF: $n = \{1,2\}$ -dnevna perioda	2
	RSI: 14-dnevna perioda RSI	1

	MACD: 12-dnevna kratka, 26-dnevna dolga in 9-dnevna signalna perioda	1
	INCL: $n = \{5,10,15,20\}$ -dnevna perioda	4
	DIFF RET: $n = \{1,2\}$ -dnevna perioda	2
	DIFF INCL	4
	COEFs	2
<b>Vsota</b>		<b>43</b>

Opombe: Tržni in delniški (finančni) podatki so bili sestavljeni iz nabora dvanajstih pojasnjevalnih spremenljivk. Časovni podatki so obsegali pet posameznih pojasnjevalnih spremenljivk. Tehnični indikatorji so predstavljali najširši del spektra pojasnjevalnih spremenljivk, saj so skupno obsegali 26 pojasnjevalnih spremenljivk. 10 spremenljivk je bilo iz nabora donosnosti (angl. Return, krajše RET), tj.  $\{1,2,3,\dots,10\}$ -dnevne donosnosti, sprememb v tečajih (angl. Difference, krajše DIFF), tj.  $\{1,2\}$ -dnevnih sprememb, indikatorja RSI, indikatorja MACD, naklona (angl. Inclination, krajše INCL, ta je bil izračunan kot regresijski koeficient na  $\{5,10,15,20\}$ -dnevni osnovi), spremembe donosnosti (angl. Change in Returns, krajše DIFF RET, ki je bil izračunan kot razlika med  $\{1,2\}$ -dnevnimi donosi), spremembe naklonov (angl. Differences in Inclinations, krajše DIFF INCL, kjer so bile izračunane razlike med 5- in prejšnjimi 5-dnevnimi nakloni, aktualnima 5- in 10-dnevnima naklonoma, aktualnima 5- in 15-dnevnima naklonoma in aktualnima 5- in 20-dnevnima naklonoma) ter dvema koeficientoma, tj. kvocient med začetnim in zaključnim tečajem, ter kvocient med najvišjim in najnižjim tečajem (oba zmanjšana za 1). Končno je celotna razširjena zbirka podatkov  $\mathbf{X}'$  zaradi lastnosti nevronske mreže bila normalizirana med 0 in 1. Vsi postopki izračuna pojasnjevalnih spremenljivk so v nadaljevanju podrobneje opisani. Vir: D. Fister, Mun, idr. (2019).

Po pridobitvi zbirke podatkov finančnih kotacij in določitvi nabora zelenih tehničnih indikatorjev so izvedeni izračuni tehničnih indikatorjev. Tehnični indikatorji so izračunani po enačbah, ki so zapisani v naslednjem podglavju.

#### 2.4.1 Izračuni tehničnih indikatorjev

Tržni, delniški in časovni podatki so bili pridobljeni neposredno s portala Yahoo Finance, medtem ko smo tehnične indikatorje izračunali lokalno. RET so bili izračunani po naslednji formuli:

$$RET_n = \frac{x_t^{(close)}}{x_{t-n}^{(close)}} - 1,$$

Kjer smo z  $x_t^{(close)}$  označili zaključni tečaj v času  $t$ , z  $x_{t-n}^{(close)}$  pa zaključni tečaj v času  $t - n$ . Pri tem se je  $n$  spreminjal med  $n = \{1,2,3,\dots,10\}$ . DIFF smo izračunali po:

$$DIFF_n = x_t^{(close)} - x_{t-n}^{(close)},$$

kjer se je  $n$  spreminjal med  $n = \{1,2\}$ , tj. izračunali smo razlike med 1- in 2-dnevnimi zaključnimi tečaji. RSI in MACD sta bila izbrana kot standardna tehnična indikatorja, ki povrh lahko nastopata kot samostojni trgovalni strategiji. Prvega izmed njiju je formaliziral Wilder (1978) in je kmalu postal eden najpopularnejših tehničnih indikatorjev, kot idejo izračuna sprememb v tečaju navzgor (angl. Up, krajše U), in navzdol (angl. Down, krajše D):

$$U = x_t^{(close)} - x_{t-n}^{(close)},$$

$$D = 0,$$

če gre za rast delniškega tečaja in:

$$U = 0, \\ D = x_{t-n}^{(close)} - x_t^{(close)},$$

če gre za padec (za obe spremenljivki  $U, D$  je vedno zagotovljeno nenegativno število; če ne gre za spremembo, sta obe vrednosti spremenljivk enaki 0). Vrednosti spremenljivk  $U, D$  sta v naslednjem koraku povprečeni z uporabo eksponentnih drsečih sredin (tako izračunamo indikator relativne moči, angl. Relative Strength, krajše RS):

$$RS = \frac{EMA(U, n)}{EMA(D, n)},$$

kjer  $EMA$  pomeni eksponentno drsečo sredino (angl. Exponential Moving Average, krajše EMA),  $n$  pa pove, koliko prejšnjih elementov vrste sodeluje pri izračunu drseče sredine, npr. avtor je predlagal  $n = 14$ . Končno je indeks relativne moči oz.  $RSI$  izračunan kot:

$$RSI = 100 - \frac{100}{1 + RS}.$$

Zaloga vrednosti indikatorja  $RSI$  tangira med (0,100). Interpretacija indikatorja  $RSI$  ni enovita, kljub temu pa je avtor predlagal, da vrednosti nad 70 predstavljajo t. i. precenjenost (angl. overbought) delnice, vrednosti pod 30 pa podcenjenost (angl. oversold).

Izračun  $MACD$  indikatorja je nekoliko zapletenejši, prav tako pa sloni na izračunu eksponentnih drsečih sredin. V letu 1970 ga je ustvaril Appel (2005). Vrednost indikatorja  $MACD$  izračunamo, kot sledi:

$$MACD = EMA(x^{(close)}, 12) - EMA(x^{(close)}, 26),$$

kar pomeni, da eksponentno drsečo sredino 26-dnevne periode odštejemo od drseče sredine 12-dnevne periode (časovne konstante so predlagane s strani avtorja, v širši praksi lahko uporabimo drugačne). Indikator  $MACD$  je nato primerjan z  $MACD$  »signalom«, ki ga izračunamo kot 9-dnevno eksponentno povprečje nad  $MACD$  oz.  $EMA(MACD, 9)$ . Indikator  $MACD$  je velikokrat vizualno predstavljen kot histogram - pri tem so skupni preseki (križanja) indikatorja  $MACD$  in  $MACD$  signala pripadajoči trgovanjski signali.

Naklon delniških tečajev je izračunan s pomočjo enostavne regresijske premice, kjer kot pojasnjevalna spremenljivka nastopa časovni trend (npr.  $cas = 1, 2, 3, 4, \dots, n$ ), kot odvisna spremenljivka pa  $n$ -cen delniških tečajev. V razširjeni zbirki podatkov  $\mathbf{X}'$  nastopajo štirje tovrstni nakloni, kjer  $n = \{5, 10, 15, 20\}$ :

$$x_t^{(close)} = \beta_1 \cdot cas_t + u_t,$$

kjer regresijski koeficient  $\beta_1$  predstavlja naklon ( $INCL_{n,t}$ ) delniškega tečaja. Spremembe donosnosti so izračunane po naslednji formuli:

$$DIFF\_RET = RET_{1,t}^{(close)} - RET_{1,t-n}^{(close)},$$

kjer  $RET_{1,t}^{(close)}$  ponazarja 1-dnevni donos zaključnih tečajev v času  $t$ ,  $RET_{1,t-n}^{(close)}$  pa 1-dnevni donos zaključnih tečajev  $n$  dni nazaj; pri tem je  $n = \{1,2\}$ .

Spremembe naklonov so bile izračunane kot:

$$\begin{aligned} DIFF\_INCL_1 &= INCL_{5,t} - INCL_{5,t-5}, \\ DIFF\_INCL_2 &= INCL_{5,t} - INCL_{10,t}, \\ DIFF\_INCL_3 &= INCL_{5,t} - INCL_{15,t}, \\ DIFF\_INCL_4 &= INCL_{5,t} - INCL_{20,t}, \end{aligned}$$

medtem ko relativna koeficienta:

$$\begin{aligned} rel\_diff\_close\_open &= \frac{x_t^{(close)}}{x_t^{(open)}} - 1, \\ rel\_diff\_high\_low &= \frac{x_t^{(high)}}{x_t^{(low)}} - 1. \end{aligned}$$

Znova poudarjamo, da sta oba relativna koeficienta predstavljala kvociente znotraj enega trgovalnega dne, prvi izmed njiju prikazuje relativni koeficient med zaključnim in začetnim tečajem, drugi med najvišjim in najnižjim tečajem. Naslednje podpoglavje opisuje gibanja na nemškem borznem trgu v opazovani periodi, dodane so analize podobnosti z drugimi finančnimi trgi, komentar gibanj in finančne stabilnosti, analiza makroekonomskega odtisa in izračun Hurstovega eksponenta, ki ponazarja dolgoročni spomin serije finančnih kotacij. Analizo podobnosti z drugimi finančnimi trgi opravimo z namenom preverjanja globalne povezanosti nemškega delniškega trga s tujimi in s tem univerzalnost gonilnikov tečajev. To pomeni, da v kolikor se bodo izkazale podobnosti med serijami, lahko trdimo, da so ITS uporabne tudi na tujih trgih. Dodatno bralca seznanimo s širšo (evropsko in svetovno) sliko na finančnih trgih; podamo kvalitativni komentar borznih gibanj in analizo makroekonomskega odtisa nemškega finančnega trga. Končno izvedemo tudi kvantitativni preizkus dolgoročnega spomina z namenom določitve period močnejše oz. šibkejše napovedljivosti finančne serije.

## 2.5 Komentar borznih gibanj

V obdobju 2010–2020 so bile razmere na svetovni (in nemški) ravni zaznamovane z okrevanjem po svetovni finančni krizi 2007–2009. Zaradi prevladujočega bikovskega trenda so številni delniški indeksi podirali dolgoletne rekorde. Scenarij se je dodobra zamenjal po letu 2019, ko je stabilnost borznega sveta zamajala nova globalna grožnja – tokrat virus pandemije. Zadnje leto analize je bilo zaradi zajetnejšega popravka (korekcije) pandemije popolnoma posvečeno medvedjemu trendu. Tovrstne razmere so bile zato odlično izhodišče za preizkušanje trgovalnih strategij.

Slika 2: Delniški indeks DAX30 v obdobju od 1. januarja 2010 do 12. maja 2020



Opombe: V splošnem je opazen bikovski trend, vrednost delniškega indeksa nekajkrat kratkotrajno preseže 13 tisoč točk. Proti koncu leta 2019 je opazna rekordna vrednost indeksa, nakar sledi nenaden in skokovit upad, ki končno vrednost indeksa zmanjša pod 11 tisoč točk. Opazni sta tudi dve vmesni obdobji prekomerne rasti in posledičnega padca, tj. v letu 2015 in med letoma 2017–2019. Vir podatkov: Yahoo Finance.

Iz slike 3 je razvidno trajno naraščanje vrednosti delniškega indeksa: na začetku opazovanega obdobja je vrednost indeksa znašala okoli 6 tisoč točk, na koncu nekaj manj kot 11 tisoč točk. Donosnost pasivne trgovalne strategije (oz. strategije kupi-in-zadrži) je znašala približno 83 odstotkov.

V opazovanem obdobju je prišlo do šestih menjav podjetij znotraj borznega indeksa DAX30:

- Salzgitter je bil nadomeščen s HeidelbergCement AG;
- Man je bil nadomeščen s Continental AG;
- Metro je bil sprva nadomeščen z Lanxess AG, nato pa še z Vonovia SE;
- K+S je bil sprva nadomeščen s ProSiebenSat. 1Media SA, nato pa še s Covestro AG;
- Commerzbank AG je bila nadomeščena s Wirecard AG in
- Thyssenkrupp AG je bil nadomeščen z MTU Aero Engines AG.

Vse menjavam je botrovala nezadostna tržna kapitalizacija. Prišlo je celo do dveh dvojnih menjav, tj. Metro – Lanxess – Vonovia in K+S – ProSieben – Covestro. V nadaljevanju obravnavamo analizo podobnosti z drugimi trgi v opazovanem obdobju, analizo makroekonomskega odtisa ter analizo dolgoročnega spomina.

### 2.5.1 Analiza podobnosti z drugimi svetovnimi borznimi trgi

Primerjava nemškega borznega indeksa DAX30 z drugimi svetovnimi borznimi indeksi kaže na precejšnjo podobnost med njimi. DAX30 in DJIA od leta 2010 do leta 2018 praktično

zasledujeta identično gibanje borznega indeksa, posledično sta zelo močno korelirana (korelacijski koeficient je presenetljivo visok, več kot  $\rho = 0,92$ ). V letih 2018–2020 pride do malenkostnega odstopanja med njima, saj začne DJIA začne naglo rasti, DAX30 pa še posebej v letu 2018 stagnirati. Pandemična kriza sočasno globoko prizadene oba indeksa, še posebej v začetku leta 2020, ko se zgodi močna korekcija navzdol, a se zdi, da ameriški DAX30 izgubi nekoliko več vrednosti kot nemški DAX30. Po negativni korekciji oba indeksa okrevata, a ne v obliki črke V, kot so sprva napovedali analitiki<sup>5</sup>.

Primerjava med DAX30 in S&P500 pokaže zelo podobno sliko (slika 4) kot primerjava med DAX30 in DJIA. Korelacijski koeficient je še nekoliko višji, čeprav ne bistveno ( $\rho = 0,94$ ), znova lahko vidimo identično gibanje obeh indeksov do leta 2018 in naknadni upad DAX30 oz. pridobivanje S&P500. Zdi se, da je S&P500 v času pandemije nekoliko manj prizadet kot DAX30 (naposled tudi manj prizadet ko DJIA), kar je zanimiva ugotovitev. S&P500 je namreč neprimerno bolj razpršen (diversificiran) kot DAX30 in DJIA, zato ga večje spremembe na borzi zamajejo relativno manj. To se še posebej kaže tudi v obdobju rasti med letoma 2012 in 2014, kjer je S&P500 veliko manj volatilen kot DJIA ali DAX30.

Na temo padanja nemškega indeksa DAX30 v letu 2018 je bilo prelitega veliko črnih. CNBC je poročal, da se je nemško gospodarstvo v letu 2018 soočilo z najhujšim medvedjim trendom v zadnjem desetletju<sup>6</sup>. Razlogi za to naj bi bili izrazita izvozna orientiranost nemškega gospodarstva, še posebej avtomobilske industrije, posledično pa tudi popularna energetska transformacija iz ogljičnih virov na zeleno energijo. Težavna je tudi nemška bančna industrija, ki zajema številne konkurenčne manjše banke, ki dobro poslujejo, a niso uvrščene v DAX30 (oz. celo niso delniška podjetja), medtem ko so na seznam DAX30 uvrščene le večje, a nekoliko šibke banke.

NASDAQ Composite je izrazito tehnološko orientiran ameriški borzni indeks. Opazimo, da se gibanje NASDAQ pomembno razlikuje od nemškega DAX30. NASDAQ je v celotnem opazovanem obdobju relativno nad DAX30. Do leta 2018 izkazuje nizko stopnjo nestanovitnosti (volatilitosti, angl. volatility) in narašča skorajda v linearnem trendu. Tudi vmesne korekcije NASDAQ indeksa pretežno ne zamajejo. Opazimo predvsem veliko višjo donosnost NASDAQ proti DAX30, prvi izmed njiju konča okoli vrednosti štirikratne donosnosti v primerjavi z začetkom, medtem ko drugi (ki je primerljiv s DAX30 in S&P500) okoli vrednosti 1,9. NASDAQ je edini indeks (ki ga obravnavamo), ki dosega popandemično okrevanje v obliki črke V. Čeprav se na prvi pogled ne zdi tako, pa sta NASDAQ in DAX30 precej korelirana, tj. vrednost korelacije  $\rho = 0,91$  ne zaostaja bistveno za konkurentoma DJIA in S&P500.


---

<sup>5</sup> <https://rollingnotes.in/news/recovery-may-actually-look-like-letter-v-only>

<sup>6</sup> <https://www.cnbc.com/2018/12/31/german-dax-faces-worst-year-in-a-decade-amid-global-uncertainties.html>



Slika 3: Koincidenca nemškega borznega trga (DAX30, »^GDAXI«) z ostalimi svetovnimi borznimi trgi



Opombe: Podatki povzeti po Yahoo Finance. Vsi indeksi so zaradi pravične primerjave relativizirani, korelacijski koeficient je izračunan na surovih podatkih. S sivo barvo je označen DAX30. »^DJI«=Dow Jones Industrial Average (DJIA), »^GSPC«=S&P500, »^IXIC«=NASDAQ Composite, »^N225«=Nikkei 225, »^N100«=Euronext 100, »^HSI«=HANG SENG.

N225 je japonski borzni indeks, ki se izmed vseh obravnavanih indeksov v tej analizi najbolj približa nemškemu DAX30. Zveza dosega korelacijo skoraj  $\rho = 0,97$ , a ni najvišja izmed vseh. N225 se od DAX30 bistveno razlikuje le v letih 2010–2014, od leta 2014 pa se giblje praktično identično kot DAX30. Sumimo, da je obdobje po letu 2014 že zaznamovano s pobiranjem Japonske iz dolgoletne stagflacije, še posebej leto 2013, ko se zgodi močan preboj navzgor. Kljub temu pa se japonski indeks močno razlikuje v letih 2010 do polovice leta 2013, ko N225 stagnira oz. miruje, nemški DAX30 pa postopno narašča. Opazimo, da je proti koncu leta 2020 gibanje obeh indeksov soosno, a kljub temu pandemična kriza japonski indeks zamaje nekoliko bolj kot nemškega, delno tudi zaradi boljše razpršitve. Opazimo, da je tudi okrevanje N225 nekoliko hitrejše v primerjavi z nemškim DAX30, a le za malenkost.

Euronext 100 (N100) sestavlja 100 blue-chip evropskih delnic iz petih držav, pri čemer večina prihaja iz Francije. Je indeks, ki je v največji meri koreliran z DAX30, saj korelacijski koeficient dosega skoraj  $\rho = 0,98$ . Kljub temu da je N100 visoko koreliran, pa večino opazovanega obdobja zaostaja za DAX30 (oz. dosega relativno manjše donosnosti). Gibanje obeh je zelo identično, korekcije navzgor in navzdol dobro sovpadajo. Najbolj odstopa N100 od DAX30 v končni donosnosti, slednja znaša za prvega le okoli 1,35 (za primerjavo DAX30 okrog 1,9). Končno obravnavamo tudi indeks HSI, tj. kitajski indeks, ki je najmanj koreliran z nemškim DAX30, saj korelacijski koeficient dosega borih  $\rho = 0,80$ . HSI je indeks, ki dosega najmanjšo

donosnost izmed vseh obravnavanih (okoli 1,1), zdi se celo, da celotno opazovano periodo stagnira. Korekcije med HSI in DAX30 sicer dobro sovpadajo, ko je nemški trg v obdobju bikovskega trenda, je podobno tudi HSI, in obratno. Kljub temu pa bode v oči dogajanje v času pandemične krize (zadnjega pol leta opazovanega obdobja), ko je DAX30 deležen močne korekcije navzdol, kitajski HSI pa le manjše. Korekcija nemškega indeksa DAX30 je tako močna, da se v prvem četrtletju leta 2020 indeksa (relativno) skorajda prekrijeta, četudi DAX30 pred krizo dosega veliko višje vrednosti donosnosti. Podrobnejša analiza pokaže, da je kitajski HSI sicer v celotnem letu 2019 relativno nekoliko manj sovpadal z nemškim DAX30, kar potencialno že nakazuje na prihajajočo negotovost na trgu, kot zanimivost pa opazimo tudi, da HSI nekoliko prehiteva. Predzadnja močnejša korekcija navzdol se zgodi že kmalu po polovici leta 2018, medtem ko pri nemškem DAX30 komaj v tretjem četrtletju, zadnja korekcija navzdol pa se na kitajskem HSI začne že takoj po novem letu 2020, medtem ko pri DAX30 šele po približno polovici prvega četrtletja. Sodeč po prikazani karakteristiki v prvem polletju 2020, HSI ne izkazuje močnejšega okrevanja.

### **2.5.2 Analiza dogajanja na finančnih trgih in finančna stabilnost EU v obdobju 2007–2020**

Finančni trgi so poleg finančnih institucij in finančne infrastrukture ena izmed temeljnih komponent finančnega sistema. Banka Slovenije finančno stabilnost opredeljuje kot stanje, v katerem komponente finančnega sistema delujejo brez sistemskih motenj in v katerem vsaka komponenta finančnega sistema zagotavlja največjo možno mero prožnega odzivanja na morebitne šoke<sup>7</sup>.

Analizo dogajanja finančnih trgov začenjamo v letu 2007. Globalni trgi so pred gospodarsko recesijo, gospodarska aktivnost upada, banke beležijo naraščajoč obseg slabih posojil, tako osebnih kot podjetniških. CB po svetu, še posebej FED, so močno angažirane, da odgovorijo na prihajajočo globalno sistemsko dolžniško krizo, pojavi se množično odkupovanje državnih obveznic in injiciranje sveže likvidnosti v finančni sistem, večinoma s tiskanjem novega denarja. Prične se doba nizke inflacije in nizkih obrestnih mer, kar prinese nove izzive tako finančnim kot tudi nefinančnim institucijam. Finančna stabilnost s krizo drastično upade, pojavljajo se novi in novi stečaji podjetij, prizaneseno ni niti največjim. Približno dve leti smo priča eni največjih svetovnih finančnih kriz, ki ne pustoši le v letih 2007–2009, temveč pusti korenite posledice tudi za prihodnost.

Akterji finančnega sistema pričnejo beg h kakovosti (angl. flight-to-quality), odkrivajo se novi krivci in razlogi za tako hipen preobrat. Zdi se, kot da je najbolj zatajil nepremičninski sektor. Sistemsko pomembnim bankam je nudena takojšnja finančna pomoč, sicer narodnim gospodarstvom po svetu grozi finančni zlom. Sistematizacija in globalna povezanost finančnih trgov je zapredla sama sebi. Okrog leta 2009 se splošni ugled finančnega sistema izboljša. CISS v EU prične upadati, kar pomembno vpliva na izboljšanje gospodarskega cikla in narodnih gospodarstev. Kljub temu ostanejo jasna dejstva, ki pričajo, da se je finančni sistem šele začel pobirati. Tečaj EUR/USD postane močno volatilen, potem ko je ta dosegel nov rekord v zadnjih 20 letih, ko je USD depreciral vse do tečaja skoraj EUR/USD=1,6; cena surove nafte v šestih

---

<sup>7</sup> <https://www.bsi.si/financna-stabilnost>

mesecih pade iz rekordnih 140 USD po sodčku na 41 USD po sodčku; indeks cene svetovne hrane pade v šestih mesecih skoraj za polovico<sup>8</sup>.

Bančni sektor po mnenju analitikov hitro okreva, kljub temu pa slednji ne skoparijo z navajanjem najaktualnejših tveganj in ranljivosti. Kot najpomembnejša poročilo ECB (2009) navaja: (1) zaradi preteklih (pre)ugodnih pogojev zadolževanja se pojavi problem hipne prezadolženosti po eni strani ter zaostreno refinanciranje dolga na račun bega h kakovosti po drugi; (2) stroški financiranja pričnejo močno naraščati, s tem se niža dobičkonosnost nefinančnih podjetij; (3) pogoji ponovnega zadolževanja se močno zaostrejejo. Kreditne institucije so zaradi padajočih cen nepremičnin priča povišanemu obsegu slabih posojil, kar jim škoduje še vrsto let po tem. Hkratno (1) znižanje gospodarske rasti in stagnacije obsega vladnih prihodkov ter (2) povišanje vladnih izdatkov na račun vladnih pomoči, finančnih injekcij ter helikopterskega denarja, vržeta slabo luč na srednje in dolgoročno vzdržnost javnih financ ter bodočo konsolidacijo, posledično je učinek izrinjanja zasebnih vlaganj (angl. crowding out) čedalje bolj opazen.

Slika 4: Makroekonomski odtis nemškega gospodarstva v opazovanem obdobju



Opombe: Podatki povzeti po Eurostat in ECB Statistical Data Warehouse. S sivo barvo je označeno gibanje indeksa DAX30. »LTIR«=angl. Long-Term Interest Rate (slov. dolgoročna obrestna mera), »UNEMP«=angl. unemployment (slov. brezposelnost).

Poročilo ECB kot najpomembnejša bodoča tveganja navaja: (1) tveganje suverenega dolga in potrebo po korenitem prestrukturiranju fiskalnega napa, (2) bojazen pred trajno vladno (davkoplavevalsko) pomočjo finančnim institucijam oz. bojazen, da se bodo finančne institucije pokazale kot nemočne pri operativnem poslovanju; špekulira se celo o optimalnem trenutku za izhod in preprečitev nadaljnega izkoriščanja moralnega hazarda, (3) povečano kreditno tveganje na trgu poslovnih nepremičnin in (4) o dvomih ter smiselnosti posredovanja CB ter vladnih agencij, v kolikor se makroekonomski obeti in pričakovanja ne uspejo realizirati.

<sup>8</sup> <https://tradingeconomics.com/>

Čeprav se zdi, da so navedena tveganja in mediacije le začasna, praksa pokaže, da slednja ostanejo aktualna še vrsto let.

V letu 2010 se položaj večine bank v EU izdatno izboljša, po večini na račun zaostrene regulative (še posebej kapitalskih blažilnikov), a po drugi strani to zmanjša njihovo dobičkonosnost (ECB, 2010). Vlada prepričuje, da je okrevanje obrodilo sadove; padanje CISS in indikatorja verjetnosti hkratnega propada dveh ali več sistemsko pomembnih finančnih institucij nakazuje na dejansko izboljšanje finančne stabilnosti; čedalje pomembnejša postajajo tveganja, posamična za vsako institucijo; rezervne kapacitete za preprečevanje eksternih šokov naraščajo. Znova je poudarjena povratna zanka med vzdržnostjo javnih financ in finančno stabilnostjo, močno trpi likvidnost nekaterih EU finančnih trgov, kar ne povzroča samo napačnih vrednotenj finančnih instrumentov, temveč tudi poslabšuje učinkovitost manevrov monetarne politike. Glede na računsko napovedi se obetajo še obsežnejša slaba posojila, zato se napovedujejo dodatne regulacijske zaostritve. Začetek leta 2011 ne prinese novosti glede slabšanja finančne stabilnosti, se pa pojavijo nova dejstva, ki nakažejo na pretirane razlike makroekonomskega odtisa med državami EU (ECB, 2011). Pri teh je vodilna Grčija, katere razpon donosnosti prične močno naraščati, zaznati gre celo obračanje grške krivulje donosnosti državnih obveznic; donosnost 10-letnih državnih obveznic prične zaradi pomanjkanja povpraševanja izrazito naraščati. Grčija je deležna EU mednarodne pomoči, tako posameznih gospodarstev (med drugim tudi vidnejše pomoči Nemčije kot gospodarske velesile EU), kakor tudi evropskih institucij in IMF. Slabšanje položaja Grčije kot ene izmed članic močno vpliva tudi na razmike instrumentov CDS v območju EU, ki pričnejo v začetku leta 2011 naraščati, ob koncu leta 2011 pa dosežejo rekordno raven.

Klasične depozitarne institucije se pričnejo spopadati s čedalje nižjimi obrestnimi merami in posledično čedalje nižjo neto profitno maržo, kmalu bodo primorane preoblikovati svoje poslovne modele. Prav tako morajo nadomestiti delež izpada financiranja na račun zmanjšane spodbude varčevalcev. Prvega januarja 2011 je ustanovljena EBA, ki od tedaj redno izvaja stresne teste bank EU. Glavna tveganja za bodoče ostajajo podobna, ECB posebej poudarja: (1) tveganja, povezana s financiranjem finančnih institucij, kar nakazuje na zmanjšano finančno stabilnost in stroške slabih posojil; (2) naraščanje dolgoročne tržne obrestne mere (vladnih obveznic) nekaterih EU držav, kar nakazuje na manko povpraševanja; (3) izrazito povečan obseg meddržavnega kapitalskega toka kot pomoč državam v stiski.

Tudi leta 2012 je v ospredju nestanovitnost obveznic in izvedenih finančnih instrumentov, še posebej CDS-ov (ECB, 2012). Kot odgovor na pričakovano stopnjevanje tveganja suverena dolga in ranljivosti javnih financ je sprejet t. i. fiskalni pakt, ki naslovi temeljne javnofinančne izzive v euro območju in spopadanje z njimi. Dobičkonosnost bank še naprej upada, pojavi se potreba po njihovem razdolževanju; obseg bilanc stanj številnih svetovnih bank po letu 2012 pričnejo trajno upadati; kot odgovor na njihovo negotovost se pričnejo pojavljati zametki t. i. fintech neobank. Nadaljuje se negotovo in nestanovitno obdobje surove nafte, ki pa se v drugi polovici leta 2012 ustali. Rast BDP na nivoju EU v začetku leta 2012 postane negativna, napoveduje se postopno okrevanje gospodarske rasti v prihodnjih letih. V sredini julija 2012 japonski jen postane najmočnejši proti euru v zadnjih dvajsetih letih, kitajski juan proti euru aprecira že vse od leta 2008. Po juliju 2012 japonski jen prične znova izgubljati, delno tudi zaradi trenda trgovinske bilance EU, ki leta 2012 postane pozitiven. V letu 2013 se izkaže, da je vrhunec krize v EU mimo; CISS v drugi polovici leta 2013 pade na najnižjo raven od leta 2011 naprej; analitiki ugotavljajo, da je kljub dobri enotnosti EU javnofinančna konsolidacija

potekala zelo različno in neenakomerno (ECB, 2013). Kljub temu prilagoditev evropskega procesa ostaja negotova, ostajajo dodatni izzivi, npr. indikator zaupanja potrošnikov v kakovost dobrin in storitev na trgu pade na najnižjo raven od leta 2011 naprej. Napoveduje se ustanovitev evropske skupne bančne resolucije, ki je leto kasneje ustanovljena. Znova se omenja nizka likvidnost nekaterih finančnih trgov, kar posledično prinaša napačna vrednotenja in oteženo vodenje monetarne politike. Višanje obsega slabih posojil je eden izmed pomembnejših razlogov za najnižji donos sredstev EU bank od leta 2009. Februarja je ustanovljena nemška neobanka N26.

V prvem četrtletju leta 2014 cene nepremičnin dosežejo najnižjo raven v zadnjih petih letih. Cena surove nafte (in nafte tipa Brent) v drugi polovici močno upade, skoraj za polovico tečaja. Razlogov za padec cene nafte je več, od nižjega povpraševanja po nafti zaradi močnega spodbujanja električnih avtomobilov, do višje ponudbe zaradi modernih tehnologij; delno tudi zaradi vezanosti na tečaj ameriškega dolarja, euro se namreč prične šibiti proti ameriškemu dolarju, s tem pa padejo tudi cene nafte (Mead & Stiger, 2015). Euro prične izgubljati tudi proti britanskemu sterlingu in kitajskemu juanu. ECB (2014) poroča, da so finančni indikatorji sicer stabilni, a da ostajajo cilji za krepitev euro območja na vrhu prioritet. Po priključitvi ukrajinskega polotoka Krima Ruski federaciji se napovedujejo konkretne geopolitične spremembe. Formirata se dve glavni vrsti tveganj v bodoče: (1) latentna, ki se nanaša na preostalo nedokončano delo v bančnem sektorju in javnimi financami ter (2) prihajajoča, ki se nanaša na čedalje opaznejši fenomen gonje za čim višjim donosom. Nekateri finančni trgi so posledično stvar premajhnega interesa in postanejo nelikvidni. Leta 2015 je finančna stabilnost euro območja na vrhuncu, CISS pade na najnižje vrednosti v obdobju od leta 2011 naprej; verjetnost hkratnega propada dveh ali več sistemsko pomembnih finančnih institucij znaša manj kot tri odstotke, kar je enako pred krizni ravni (ECB, 2015). Že v začetku leta dobi indeks Euro Stoxx nov zagon, saj močno naraste; donosnosti podjetniških obveznic že od začetka 2012 konstantno upadajo, naraščajo tudi tečaji drugih finančnih instrumentov. Obstajajo tudi slabosti, obseg bančnih posojil gospodarstvu konstantno upada že od leta 2011; obseg realnih vlaganj ostaja v zadnjih treh letih stacionaren, zdi se kot da celo stagnira, še vedno je pod pred krizno ravno; napoveduje se nov val negotovosti iz naslova zamujanja realnih vlaganj glede na dogajanje na finančnih trgih. Večina klasičnih bank beleži nižji donos na lastniški kapital od tehtanih stroškov kapitala. Marca 2015 se prične nov, razširjen val kvantitetnega sproščanja, posledično monetarni agregat M1 prične prelomno naraščati (trend naraščanja je linearen). Zaradi geopolitičnih nesoglasij na bližnjem vzhodu se pojavi evropska imigrantska kriza, Nemčija kot velesila EU sprejme največ imigrantov od vseh EU držav. Razmik med donosnostmi kratkoročnih in dolgoročnih obveznic prične znova upadati (tako v EU kot v US), upad spominja na dogajanje v letih 2004–2007. Krize, povezane z geopolitičnimi spremembami na globalni ravni, še posebej državam v razvoju, se pričnejo stopnjevati.

V letu 2016 pade ECB ključna obrestna mera MRO-jev na zgodovinsko vrednost – nič. Tako se kljub dobrim obetom nadaljuje močno prilagodljiva (akomodativna) monetarna politika, CISS prične znova naraščati. Pojavijo se nova geopolitična in strateška vprašanja – izstop Velike Britanije iz EU; ameriške predsedniške volitve med Clintonovo in Trumpom. Nestanovitnost na finančnih trgih se poveča do te mere, da se celo napovedujejo možni hipni preobrati na trgih (ECB, 2016). Zmanjšana neto obrestna marža klasičnih bank predstavlja čedalje večje izzive; še vedno se te ubadajo s povišanim obsegom slabih posojil; veliko bank še vedno posluje z nedopolnjenimi poslovnimi modeli. Pojavijo se navali na nekatere vzajemne sklade odprtega tipa, kar sproži polemike o tveganjih tovrstnih nedepozitarnih finančnih institucij. Tudi leto

2016 je v glavnini posvečeno političnim ter geopolitičnim vprašanjem, narašča pomembnost globalnega tveganja, ki lahko znova vodi do ponovnih sistemskih izpadov. Izvoz EU prične v letu 2016 postopoma naraščati, s čimer se krepi makroekonomski odtis EU, pričakuje se močnejši euro. Brezposelnost, ki v trendu upada, postane aktualen in popularen indikator politikov in ostalih usmerjevalcev politike. Stroški prehrane po svetu zaradi izredno ugodne letine upadejo, kar po eni strani relativno zmanjša pritiske na HICP, po drugi strani pa prinese prestrukturiranje izdatkov gospodinjstev. Zaradi dolgotrajnejšega in intenzivnega QE se sprožijo polemike o bodoči inflaciji. ECB (2017) poroča o ena in pol odstotnem povišanju cen življenjskih potrebščin; jedrna inflacija, ki ne upošteva stroškov prehrane in transporta, se v zadnjih štirih letih ne spreminja bistveno. Med govoricami je moč občutiti, da se pripravljata zatišje pred novo gospodarsko krizo.

Bilance stanj CB po svetu so močno napihnjene, FED poskuša za krajši čas znižati obseg bilance. CB so v čedalje večji meri tarče polemik o monetizaciji dolga zaradi držanja državnih obveznic do zapadlosti. Indeks cen nepremičnin prične močno naraščati, v EU državah je moč zaslediti izredno povečano povpraševanje po nepremičninah; čedalje več vlagateljev po EU mestih se odloča za vlaganja v nepremičnine kot naložbe, kar vodi k novemu nepremičninskemu balončku in pomanjkanju ponudbe. Obsegi suverenih dolgov držav EU dosežajo zgodovinske vrednosti; ključno makroekonomsko tveganje izvira iz premij za ročnost državnih obveznic (ECB, 2018). V letu 2019 smo pričali skoku jedrne inflacije, ki pa je do konca leta zadušena; HICP poskoči za veliko več. Indikator bodočega splošnega gospodarskega položaja prične v državah EU močno upadati, s čimer se napovedujejo bodoče finančne težave; zasebna vlaganja upadejo skoraj za četrtno, pade tudi indikator gmotnega stanja gospodinjstev; močno prične upadati indikator zaupanja potrošnikov v kakovost proizvodov na trgu, približa se vrednostim iz leta 2017; brezposelnost še vedno upada, do konca leta 2019 na EU ravni upade pod delež 7,5 odstotka. Sprožijo se globalne polemike o pomenu, trendu in potrebi po digitalizaciji v prihodnjih letih (ECB, 2019).

Končno leta 2020 udari nova svetovna kriza, tokrat pandemična. Finančni trgi utrpijo močne popravke navzdol; pričnejo se sprejemati najrazličnejše monetarne, fiskalne in politične mediacije; napovedujejo se prestrukturiranja po praktično vseh sektorjih; suvereni dolgovi držav po svetu znova izrazito narastejo zaradi večjih obsegov vladnih pomoči in izplačil prizadetim. Sproži se nov val QE, tokrat pandemičnih pomoči, obseg monetarnega agregata M1 prične v letu 2020 znova prelomno naraščati, močno se krepijo obsegi bilanc stanja CB po svetu; VIX skoči na podobne ravni kot leta 2016 (ECB, 2020). Najbolj utrpi transportni sektor, čigar obseg se močno zmanjša (nemška vlada prepreči stečaj ene največjih letalskih družb Lufthanse); cena surove nafte zaradi izredno zmanjšane povpraševanja močno pade (po letu 2020 se izkaže, da je ta nekaj dni celo negativna, tj. okrog -38 dolarjev po sodčku); pojavijo se izrazite motnje v dobavnih verigah, gospodarska rast posledično močno nazaduje. CISS hipno poskoči, a doseže le okrog polovico vrednosti iz let 2011–2012. Izkaže se, da je tokrat v ospredju krize namesto finančnega sektorja transportni.

### **2.5.3 Analiza dolgoročnega spomina borznih kotacij s Hurstovim eksponentom**

Namen doktorskega dela ni bil preizkušati veljavnost EMH za nemški indeks DAX30, kljub temu smo izvedli preizkus dolgoročnega spomina borznih kotacij s Hurstovim eksponentom. Rezultati Hurstovega eksponenta lahko nakazujejo na prisotnost dolgoročnega spomina serije, kar je dober nadomestek za ocenjevanje učinkovitosti EMH. Madura (2012) namreč navaja, da

so v preteklosti šibko učinkovitost EMH že testirali z iskanjem nenaključnih avtokoreliranih vzorcev.

V splošnem predpostavljamo, da EMH ne drži, saj trdimo, da je mogoče z aktivno ITS doseči donos, višji od indeksa, kar posledično pomeni, da je moč s preteklimi vzorci tečaja in razumnimi sklepanji napovedati prihodnja gibanja. To predpostavko lahko z uporabo metode Hurstovega eksponenta empirično preverimo in pri tem ugotovimo, ali je trg napovedljiv oz. kdaj je bolj ali manj napovedljiv.

Hurstov eksponent je uvedel Hurst (1951) za potrebe ocenjevanja optimalne ravni jezua na reki Nil, zaradi enostavnosti pa se je Hurstov eksponent uveljavil v splošnem kot mera dolgoročnega spomina v časovni vrsti. Kot pravita Qian & Rasheed (2004), ki med drugim eksplicitno zapišeta, da se DJIA med leti 1930 in 2014 ne pokaže kot popolnoma naključna serija, se Hurstov eksponent uporablja kot mera za napovedljivost, zato ga srečamo na najrazličnejših področjih, od finančnega inženiringa (Grech & Mazur, 2004) do ekologije (Y. Z. Wang et al., 2011). Ideja Hurstovega eksponenta temelji na izračunu pričakovane vrednosti reskaliranega razpona (angl. rescaled range):

$$E \left[ \frac{R(n)}{S(n)} \right],$$

pri čemer  $E$  predstavlja povprečno pričakovano vrednost (aritmetično povprečje),  $n$  označuje število elementov v časovni vrsti,  $R$  je dejanski razpon odstopanj serije  $n$  vrednosti od povprečne vrednosti in  $S(n)$  je vsota prvih  $n$  standardnih odklonov. Hurst je ugotovil, da lahko zgornjo formulacijo enači s:

$$C \cdot n^H,$$

pri čemer gre  $n$  preko vseh mej ( $n \rightarrow \infty$ ),  $C$  pa predstavlja konstanto. Končno vpeljemo eksponent  $H$  oz. Hurstov eksponent. Vidimo, da gre za nelinearno zvezo med reskaliranim razponom in delom  $C \cdot n^H$ , z naraščanjem  $H$  se ta del eksponentno povečuje. Zvezo si zato lažje predstavljamo po anti-logaritmiranju oz. v logaritemski skali, kjer Hurstov eksponent predstavlja naklon linearne premice. Hurst je empirično določil, da se vrednosti  $H$  gibljejo med  $0 < H < 1$ , pri čemer ločimo tri različne intervale:

- $0 < H < 0,5$ : serija izkazuje negativno avtokoreliranost, na dolgi rok je prisotno pogosto menjavanje med visoko in nizko vrednostjo; na kratki rok sledi padcu vrednosti tečaja rast, in obratno; manjši kot je Hurstov eksponent, tem bolj je serija napovedljiva.
- $H = 0,5$ : serija ni avtokorelirana, zato je težko napovedljiva; tak primer je npr. Brownovo gibanje.
- $0,5 < H < 1$ : serija izkazuje pozitivno avtokoreliranost, povečevanju tečaja vrednosti bo najverjetneje sledila nadaljnja rast, in obratno (padcu bo sledil dodaten padec); večina delnic v vzorcu se nahaja znotraj tega intervala (Qian & Rasheed, 2004). Višji ko je Hurstov eksponent, tem bolj je serija napovedljiva.

V nadaljevanju je priložen postopek izračuna Hurstovega eksponenta, notacija sledi izračunu knjižnice *hurst*<sup>9</sup>. Vhod v izračun Hurstovega eksponenta je serija delniških podatkov *series<sub>i</sub>*, ki vključuje *n* elementov. Serija ne sme vključevati neznanih (nedoločenih, tj. nan) vrednosti, priporočljivo je, da serija vključuje vsaj 100 elementov ( $n \geq 100$ ). Hurstov koeficient izračunamo s pomočjo enostavne bivariatne linearne regresije na vzorcu podoken. Postopek pričnemo z določitvijo minimalne in maksimalne dolžine podokna, pri čemer minimalno dolžino tipično fiksiramo pri  $min\_window = 10$ , maksimalno dolžino pa tipično enačimo z dolžino serije  $max\_window = n$  (podamo lahko tudi alternativne vrednosti obeh spremenljivk). Iz podanih spremenljivk sestavimo vektor *window\_sizes<sub>j</sub>*, ki vključuje *m* elementov (ravno *m* elementov bo velikost vzorca za izračun linearne regresije), kot sledi:

$$window\_sizes_j = \log_{10}(min\_window) + l \cdot 0,25, \quad \forall l \in \{0,1, \dots, n \cdot 0,25 < \log_{10}(max\_window)\},$$

pri čemer zapisan vektor vključuje le  $m - 1$  elementov, zato slednjemu kot *m*-ti element dodamo  $\log_{10}(max\_window)$ . Vektor *window\_sizes<sub>j</sub>* zaokrožimo na cela števila  $window\_sizes_j = \lceil window\_sizes_j \rceil$  (opisana operacija spominja na funkcijo, ki naslovi linearne preskoke, npr. *linspace* oz. *arange*). V naslednjem koraku tako pridobljen vektor anti-logaritmiramo:

$$window\_sizes_j = 10^{window\_sizes_j}.$$

Za vsak element anti-logaritmiranega vektorja *window\_sizes<sub>j</sub>* izračunamo linearno serijo od 0 do *t* z linearnim preskokom *window\_sizes<sub>j</sub>*, kot sledi:

$$start_k = 0 + window\_sizes_j \cdot l, \quad \forall l \in \{1,2, \dots, t\},$$

pri čemer pazimo, da  $window\_sizes_j \cdot t < n$ . Nadalje za vsak element *start<sub>k</sub>* izračunamo vrednost reskaliranega razpona *rs<sub>k</sub>*, kot sledi:

$$rs_k = RS\_func\left(series_{start_k:start_k+window\_sizes_j}\right),$$

kjer *RS\_func* predstavlja funkcijo izračuna reskaliranega razpona, pri tem velja  $start_k + window\_sizes_j < n$ . V nadaljevanju serijo  $series_{start_k:start_k+window\_sizes_j}$  označimo kot *x<sub>p</sub>*, ta vključuje *window\_sizes<sub>j</sub>* elementov.

Reskaliran razpon za serijo *x<sub>p</sub>* izračunamo po sledečem postopku, najprej določimo dnevne spremembe (inkremente oz. dekremeente), kot sledi:

$$incs_p = x_{2:} - x_{:-2},$$

pri čemer z *incs<sub>p</sub>* označimo izračunane spremembe (t. i. inkremente), *x<sub>2:</sub>* ponazarja serijo od drugega elementa naprej, *x<sub>:-2</sub>* pa ponazarja serijo do predzadnjega člena. Pridobljena serija

---

<sup>9</sup> <https://github.com/Mottl/hurst/>



$incsp$  vključuje  $window\_sizes_j - 1$  elementov. Nato izračunamo srednjo vrednost sprememb, kot sledi:

$$mean\_inc = \frac{x_{-1} - x_1}{n},$$

pri čemer  $x_{-1}$  označuje zadnji element serije,  $x_1$  pa prvega. Naprej določimo odstopanja dnevni sprememb  $deviations$  od njihove srednje vrednosti, kot sledi:

$$deviations_p = incsp - mean\_inc,$$

Nadalje izračunamo maksimalni razpon kumulativne vsote sprememb  $R$  in vzorčni standardni odklon sprememb  $S$ :

$$Z_o = \sum_{p=1}^o deviations_p, \forall o \in \{1, 2, \dots, window\_sizes_j\},$$

$$R = \max(Z_o) - \min(Z_o),$$

$$S = \text{std}(incsp),$$

pri čemer  $Z_o$  predstavlja kumulativne vsote za vsak dotični element vektorja. Končno izračunamo reskaliran razpon  $R_{razpon}$  (ki je skalar), kot sledi:

$$R_{razpon} = \frac{R}{S}.$$

Rezultat shranimo v vrsto  $rs_k$ . Ko predvajamo vse elemente serije  $start_k$ , izračunamo srednjo vrednost serije  $rs$  in rezultat shranimo kot element serije  $RS_j$ :

$$RS_j = \overline{rs}.$$

Hurstov koeficient izračunamo z uporabo dvojno logaritemske linearne regresije najmanjših kvadratov:

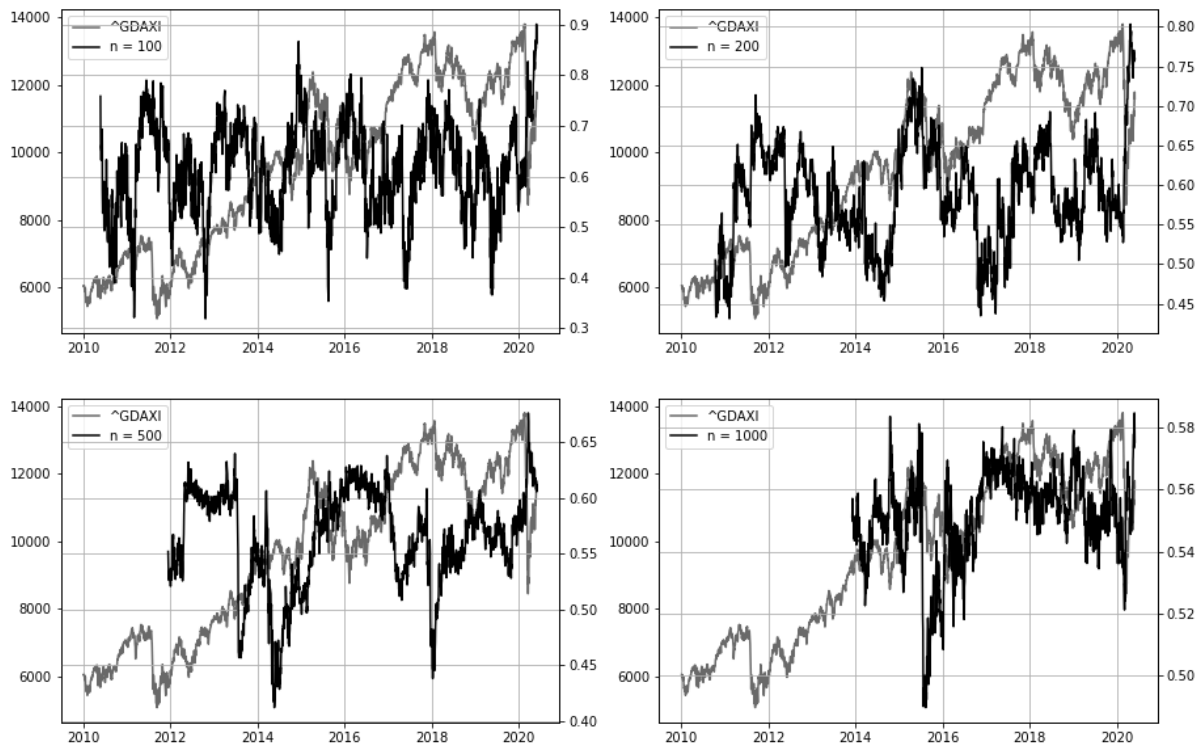
$$\log_{10} RS_j = \log_{10} \beta_1 + \beta_2 \cdot \log_{10} window\_sizes_j + u_j,$$

pri čemer regresijski koeficient  $\beta_2$  predstavlja Hurstov eksponent,  $u_j$  pa ostanke regresijskega modela. Izpolnjevanja predpostavk linearne regresije ne preverjamo, a je kljub temu vredno omeniti, da so ocene regresijskih koeficientov najboljše možne le, če se (1) ostanki porazdeljujejo normalno, če imajo (2) ostanki konstantno varianco ob različnih presekih (so homoskedastični), in če so (3) ostanki neodvisni, tj. ne obstaja korelacijska zveza med zaporednimi ostanki. Če teh predpostavk ni mogoče zagotoviti, obstajajo boljše cenilke od uporabljene cenilke najmanjših kvadratov, kljub temu pa vrednosti regresijskih koeficientov (ki jih v nadaljevanju vizualiziramo) ostajajo nepristranske.

Za celotno serijo izračunamo vrednost eksponenta  $H = 0,5203$ . Rezultate delnih Hurstovih eksponentov na drsečih oknih, tj. regresijskih koeficientov  $\beta_2$  vizualiziramo grafično na sliki 2; ta prikazuje izračune na štirih različno dolgih drsečih oknih  $n = \{100, 200, 500, 1000\}$ , od tod

štirje odseki. Za primerjavo je na vsakem odseku posebej pripravljena osnovna serija delniškega indeksa z levo orientirano osjo. V začetnih periodah rezultatov se pojavljajo nedoločene vrednosti, za katere Hurstovega eksponenta ne izračunavamo. Manjši kot je  $n$ , tem bolj občutljivo lahko zaznamo ponovljivost serije; večji kot je  $n$ , tem večje je dušenje in tem splošnejše vzorce lahko zaznamo.

Slika 5: Izračuni Hurstovega eksponenta



Opombe: Prvih  $n$  observacij rezultat Hurstovega eksponenta zaradi drsečega okna ni dostopen.  
 » $\hat{GDAXI}$ «=vrednost tečaja DAX30,  $n$  predstavlja dolžino drsečega okna za izračun Hurstovega eksponenta.

Rezultati na sliki 2 kažejo, da vrednosti Hurstovega eksponenta z daljšanjem časovnega okna upadajo. Medtem, ko je pri  $n = 100$  moč zaslediti razpon vrednosti med  $0,33 < H < 0,90$ , je pri  $n = 1000$  moč zaslediti le razpon med  $0,61 < H < 0,49$ . Dejstvo nakazuje na čedalje manjšo napovedljivost trga na dolgi rok, v primerjavi s kratkim rokom. Posledično je Hurstov eksponent na kratki rok tudi veliko bolj volatilen. Vrednosti Hurstovega eksponenta  $H$  se na kratki rok gibljejo v okolici  $H = 0,60$ , na dolgi rok pa upadajo, pri  $n = 1000$  se gibljejo okoli vrednosti  $H = 0,55$ . Iz opravljenih preizkušanj lahko izpeljemo trditev, da je opazovan trg bolj napovedljiv na kratki rok. Pri tej zvezi gre za pozitivno avtokorelacijo, kar pomeni, da se rast tečaja odraža v nadaljnji rasti, upad tečaja pa v nadaljnjem upadu. S korekcijami tečaja se hipno in bistveno spreminja tudi vrednost Hurstovega eksponenta, kar je opazno tako na kratki kot na dolgi rok. Sodeč po tem je trg najbolj napovedljiv ob (1) preokretih trendov, npr. krizah, kjer se pojavljajo kratke, a izrazite špice (zadnja pandemična kriza močno poveča vrednosti Hurstovega eksponenta, na kratki rok celo  $H = 0,90$ ), (2) v časih linearne in enakomerne rasti/padcev, kjer so vrednosti Hurstovega eksponenta manj izrazite, a vztrajajo dlje časa. V teh dveh obdobjih lahko, sodeč po vzorčnih rezultatih, izpeljemo, da je nemški trg delno oz. popolnoma neučinkovit, in da obstajajo možnosti za presežni donos. Iz vedenjske ekonomije vemo, da so krize in posledični preokreti trendov močno psihološko breme za vlagatelje, ki se

takrat bolj kot racionalnih poslužujejo čustvenih odločitev (Shiller, 2003); podobno je pri ekstenzivnih trendih rasti, ki spominjajo na napihovanje balončka in manije. Kjer so prisotne neučinkovitosti, so prisotni tudi hitre in globoke poteze vlagateljev, ki kot udeleženci na trgih odpravljajo to neučinkovitost/nesorazmernost, saj so za to aktivnost (če se ne zmotijo) nagrajeni.

Če torej vemo, da obstajajo neučinkovitosti in vemo tudi, da bo pri pojavu teh prišlo do močnih korekcij, je najbolj ključnega pomena karseda hitro in objektivno prepoznati te bližajoče neučinkovitosti in zavzeti pripadajoče pozicije na trgu, ki bodo predvidoma zagotavljale presežni donos.

## 2.6 Predlagana rešitev

Pregled literature je pokazal številna znanstvena in strokovna dela na temo mehanskega oz. avtomatiziranega trgovanja. Huang idr. (2019) so povzeli glavne značilnosti in lastnosti MTS-ov, njihovo donosnost in težave, ki nastopijo ob njihovi uporabi. Chiang idr. (2016) so predstavili učinkovit MTS, ki je sposoben sprotnega prepoznavanja trgovalnih vzorcev na borzi in posodabljanja na najaktualnejše razmere. Kot uporabno vrednost modela avtorji smatrajo napovedovanje prihodnjega tečaja delnice. Tovrsten sistem je moč uporabiti neposredno pri trgovanju, ali posredno kot t. i. sistem priporočanja (angl. recommendation system). Kot zanimivost – avtorji so za namen skrajšanja učnega postopka nevronske mreže, ki se je pokazal kot problematičen, uporabili kombinacijo vzratnega razširjanja napake (angl. Backpropagation, krajše BPG) in optimizacijskega algoritma teorije rojev delcev (angl. Particle Swarm Optimization, krajše PSO). Jagrič idr. (2010) so prikazali primer MTS-a na slovenski borzi, pri čemer je bil osnovni namen raziskovanje vzorcev obnašanja delničarjev/vlagateljev. Avtorji so uporabili t. i. samoorganizirajočo se nevronske mrežo (angl. Self Organizing Map, krajše SOM), pri čemer so preizkušali različne scenarije trgovanja na podatkih razširjenih podatkih borznega indeksa in razširjenih podatkih ene izmed kotirajočih delnic na slovenski borzi. Pri tem so ugotovili močno (ključno) povezavo vedenjskih vzorcev do sprejemanja trgovalnih odločitev.

Parikh & Shah (2015) sta izvedla raziskavo uporabnosti MTS s pomočjo tehnik podatkovnega rudarjenja (angl. Data Mining, krajše DM). Avtorja sta preizkusila idejno zasnovo MTS-a na indijskih delnicah v razponu več kot 10 let. Ta raziskava se od ostalih pomembno loči, ker sta avtorja namesto simuliranja mehanskega trgovanja s preteklimi podatki (angl. backtesting) uporabnost metode sodila po standardnih klasifikacijskih metrikah (npr. priklic, natančnost, specifičnost, točnost ...). Avtorja sta celo predlagala idejno zasnovo, da bi tovrsten MTS model bilo mogoče posebiti glede na zahteve vlagateljev, npr. minimalni pričakovani donos, raven tveganja, časovno obdobje investiranja, maksimalno pričakovano izgubo, ipd., kar bi ustrezno prilagodilo trgovalne odločitve. Dbouk idr. (2014) so raziskali učinkovitosti tehničnega trgovanja na razvijajočih se trgih (angl. emerging markets) na primeru arabskih delnic. Sklep raziskave so raziskovalci zapisali enostavno in svojevrstno – tehnična analiza (tehnična pravila) na borzi ne zagotavlja ekonomsko oz. statistično upravičljivih donosov. Ravno nasprotno sta ugotovila Chong & Ng (2008), ko sta primerjala uporabnost dveh klasičnih trgovalnih strategij – MACD in RSI na osnovi 60-letnih podatkov za priljubljen britanski delniški indeks London Stock Exchange FT30. Ugotovila sta, da tehnična pravila indikatorjev MACD in RSI lahko zabeležijo višje donosnosti kot pasivna (kupi-in-drži) trgovalna strategija v večini primerov. Tudi Wong idr. (2003) so pokazali uporabnost tehnične analize, kar je bil razlog, da so avtorji

že leta 2003 objavili novico, da podjetja pogosto zaposlujejo tehnične analitike. Avtorji so izvedli raziskavo na osnovi delnic, kotirajočih na Singapurski borzi (angl. Singaporean Stock Exchange, krajše SES), kjer so uporabili različne časovne konstante drseče sredine in indikatorja RSI. Izpostavljena je bila ključna lastnost tehničnih indikatorjev – kako določiti pravi čas za trgovanje odločitev. Rezultati so pokazali, da se tehnično trgovanje popolnoma obrestuje in da lahko prinaša statistično značilne donose.

Teixeira & De Oliveira (2010) sta primerjala donosnost nabora tehničnih indikatorjev s klasično pasivno trgovanje strategijo in pri tem ugotovila, da je predlagana trgovanje strategija znatno premagala pasivno (glede na donosnost, angl. profitability). Metoda je slonela na algoritmu  $k$ -najbližjih sosedov, katero so avtorji dodatno dodelali, medtem ko je preizkušanje potekalo na delnicah, ki so kotirale na brazilski borzi. Ruta (2014) je objavil eno bolj prepoznavnih znanstveno-strokovnih del s področja ATS. Ruta je implementiral zbiranje masovnih podatkov, ki jih je nato obdeloval z metodami ML. Večina podatkov je bila dostopna na minutni osnovi; avtor je zajel več kot 100 različnih trgov (nekaj jih je izločil iz analize). Eksperimentalni rezultati so bili izvedeni s simulacijami trgovanja in so v prvi vrsti pokazali na izvedljivost tovrstne zasnove. Avtor je priložil tudi graf trgovanja v letih od 2001 do 2014, pri čemer je jasno razviden konstanten trend naraščanja donosnosti. Dodatno je avtor izvedel tudi analizo tveganja portfelja, pri čemer je ugotovil vrednosti povprečnih Sharpeovih kvocientov več kot 2. Creamer (2012) je pokazal uporabnost metode ML, tj. »logitboost« za optimalno izbiro tehničnih indikatorjev z več različnimi trgovanjskimi strategijami. Pri tem je bil algoritem logitboost mišljen kot orodje za kalibracijo modela tehnične analize. Avtor je idejo preizkusil na visoko frekventnih podatkih na dveh terminskih trgih, tj. Dow Jones Euro Stoxx 50 futures (FESX) in DAX futures (FDAX). Predlagana metoda je značilno premagala običajno tehnično analizo z običajnimi nastavitvami, kar nakazuje na dejstvo, da je že osnovna tehnična analiza lahko zelo uporabna, v kolikor si jo uporabnik zna prikrojiti. Posledično je implementiral tudi agentni sistem, ki je trgoval na terminskih trgih, in pri tem premagal klasično pasivno trgovanje strategijo. Kot zanimivost naj omenimo tudi delo Shynkevich-a (2016), ki je izvedel raziskavo klasičnih trgovanjskih strategij na področju napovedovanja donosov obveznic.

Izziv, s katerim smo se ukvarjali v tej raziskavi, se je nanašal na razvoj novih avtomatiziranih trgovanjskih strategij na osnovi AI. Predložili smo dve ločeni trgovanjski strategiji na osnovi ANN, tj. strategijo na osnovi LSTM in strategijo na osnovi SNN. S prvo izmed njiju smo želeli preveriti tezo, da je trgovanje kot klasifikacijski problem možno reševati s pomočjo LSTM, pri tem pa dobljene donosnosti, ki jih izrazimo s simuliranim (backtesting) trgovanjem, prekašajo klasične trgovanje strategije. Z drugo strategijo smo želeli eksperimentalno preveriti hipotezo, ali se da SNN uporabiti za namene trgovanja, tj. ali so zmožne generiranja smiselnih trgovanjskih signalov. Glede na dejstvo, da je razvoj SNN v fazi raziskovanja šele v začetni fazi; SNN namreč pestijo številne težave z natančnim kodiranjem podatkov in učnimi postopki (stroka zaenkrat ni poistovetena glede teh), smo želeli podati tudi empirične predloge za njihovo širšo uporabnost. Največji prispevek pri tem smo pričakovali od fizičnega elektronskega vezja, ki bi posnemal delovanje bioloških možganov. Zaradi zahtevne časovne kompleksnosti izvajanja razširjanja in učenja SNN smo želeli prav tako razviti namensko strojno opremo, za katero smo smatrali, da bi utegnila pohitrili postopek trgovanja. Naša raziskava se je od ostalih razlikovala po (1) obsežnosti primerjav različnih skupin trgovanjskih strategij na razpršenem portfelju (pogosto se raziskovalci ukvarjajo izključno z eno delnico/indeksom), (2) izbiri borznega trga – v širši praksi prevladujejo ameriški trgi, nas je zanimal osrednji evropski trg, (3–4) uporabe LSTM in SNN za razpršeno trgovanje na dnevni osnovi; pri tem se zaradi prilagodljivosti LSTM

se ponuja več različnih scenarijev izkoriščanja, npr. posamični model LSTM za vsako delnico posebej ali enotni model, ki pokriva celotni portfelj (rezultati analize so se pokazali kot presenetljivi), (5–6) preizkušanja in poročanja empiričnih ugotovitev na področju kodiranja vhodnih podatkov in učenja SNN, ter (7) implementacije SNN razširjanja na namenski strojni opremi, npr. FPGA, ki bi zmanjšala čas odločanja MTS (v večjih finančnih centrih poteka trgovanje znotraj mili sekundnih časovnih konstant, zato je hitrost izvajanja ključnega pomena).

Disertacija je plod večletnega dela na področju ATS. V delu D. Fister, Mun, idr. (2019) je bila predstavljena zasnova predlaganega MTS z LSTM na eni delnici. Enostavno, t. i. »Plain vanilla«, LSTM mrežo smo predstavili kot fiksno orodje ter spremljali učinek časovnega horizonta na trgovanje učinkovitost. Kasneje smo ogrodje dodelali – LSTM smo poglobili ter statično konfiguracijo mreže predelali v dinamično (angl. online), kar pomeni, da se je bila osnovna mreža zmožna prilagajati naknadnim najnovejšim informacijam D. Fister & Jagrič (2019). Popolno orodje na celotnem delniškem portfelju, kot je predstavljeno v tej disertaciji, je bilo objavljeno v D. Fister idr. (2021). Iz naslova SNN mrež je bilo izvedeno vabljeno predavanje na TU Graz.

Struktura disertacije: tretje poglavje obravnava finančne trge, MTS na splošno ter tematiko avtomatiziranih trgovanih strategij. Sledi pregled tehničnih indikatorjev, ki nastopajo v raziskavi, eksperimentiranja z LSTM, eksperimenti in rezultati. Četrto poglavje je namenjeno eksperimentiranju s SNN. Predstavljeni so matematično ozadje in variante učnih algoritmov, kakor tudi implementacije na namenski strojni opremi. Končno sledijo eksperimenti in rezultati. Disertacija se zaključuje s petim poglavjem – sklepom, kjer so navedene nove ugotovitve in spoznanja.



### 3 FINANČNI TRGI, MEHANSKI TRGOVALNI SISTEM IN LSTM

Tretje poglavje obravnava kratki opis finančnih trgov, opis MTS in eksperimentiranja z LSTM. Poglavje zajema pet podpoglavij, prične se z opisom značilnosti finančnih trgov in EMH. Podrobneje je opisana zasnova MTS, tudi z več priloženimi viri literature, ki obravnavajo podobno snov. Drugo podpoglavje opredeljuje ANN s povratno zanko in zajema dva dela. Sprva so predstavljene RNN, nato še LSTM. Namen tega podpoglavja je bralcu razložiti in prikazati kako izgledajo ANN s povratno zanko, zakaj so uporabne, kakšni tip podatkov lahko procesirajo in kako se izkoriščajo. Tretje podpoglavje predstavlja sintezo LSTM, tj. organizacijo LSTM kot ITS. Podrobneje sta predstavljeni dve različni ogrodji LSTM, enotni in posamični model. Nadalje je opisan način tvorjenja odvisne spremenljivke in učni algoritem za LSTM; zaradi izvrstnih sposobnosti učenja in popularnosti med raziskovalci je izbran algoritem Adam. Končno sledijo eksperimentiranja, izvedeni so trije preizkusi. Namen poglavja je na primeru vzorca eksperimentalno preveriti veljavnost teze in hipoteze H1. Poglavje o eksperimentih zajema tudi opredelitev nadzornih parametrov LSTM in kratko tolmačenje meril za ocenjevanje kakovosti ITS. Kot prvi so prikazani rezultati preizkusa koncepta, namen tega je preizkusiti, ali se LSTM kot ITS sploh lahko izkorišča. Sledi preizkus robustnosti, namen tega je preizkusiti sposobnosti LSTM kot ITS na primeru večjega vzorca, tj. desetih zagonov. LSTM je namreč predstavnih stohastičnih algoritmov, kar pomeni, da je pridobljena rešitev v vsakem zagonu nekoliko drugačna. Kot zadnje je izvedena detajlna analiza, ki se sicer nanaša na rezultate, pridobljene v drugem preizkusu. Rezultati detajlne analize so nanizani tabelarično, namen analize je bralcu približati sposobnost trgovanja LSTM kot ITS, izraženo s finančnimi indikatorji. V zadnjem podpoglavju je zapisana diskusija, ki je omejena na najosnovnejše ugotovitve, širše ugotovitve pa so podane v sklepu naloge.

#### 3.1 Finančni trgi

Finančni trgi so poleg finančnih institucij in finančnih instrumentov najpomembnejši gradniki finančnega sistema (Prohaska, 2004). Omogočajo prenos finančnih prihrankov od suficitnih gospodarskih enot do deficitnih gospodarskih enot, ki prihranke uporabljajo za pokrivanje svojih potreb. Ločimo štiri osnovne vrste finančnih trgov: primarni, sekundarni, terciarni in kvartarni. V splošnem so to fizična ali virtualna središča, kjer se srečujeta ponudba in povpraševanje vlagateljev. Na finančnih trgih se trguje z vrednostnimi papirji kratkoročnega (denarnega) ali dolgoročnega (kapitalskega) trga (Strašek & Jagrič, 2008), pri čemer za slednje nadalje ločimo dolgoročne dolžniške (obvezniške) in lastniške (delniške) vrednostne papirje. V tej raziskavi smo se ukvarjali z delniškimi vrednostnimi papirji, zato jih velja podrobneje predstaviti.

Delniški vrednostni papirji ali vrednostni papirji kapitalskega trga s spremenljivim donosom vlagatelju v zameno za finančne prihranke podeljujejo delež v lastnini delniške družbe (Prohaska, 2004), z njimi pa so povezane tudi nekatere druge pravice, kot npr. pravica do glasovanja na skupščini delničarjev, do izplačila dividend, do nakupa novih delnic, do obveščanja in do deleža v likvidacijski masi (Prohaska, 2004). So finančni instrumenti brez dospelja, z njimi se največkrat trguje na sekundarnih trgih, večinoma na borzi. Za delniške vrednostne papirje je značilno, da za njih ne obstaja vnaprej določena stopnja donosa (kot npr.

za dolžniške vrednostne papirje), se pa lahko ta približno oceni s t. i. pričakovano stopnjo donosa. Slednja je seveda odvisna od subjektivnega mnenja in metode vrednotenja vsakega posameznega vlagatelja; v preteklosti se je oblikovalo več metod vrednotenja (analiz) delniških vrednostnih papirjev.

Analiza delniških vrednostnih papirjev (v nadaljevanju delnic) je ponavljajoč se postopek ocenjevanja notranje vrednosti delnice oz. pričakovane stopnje donosa. Pri tem velja, da je višji pričakovan donos neposredno povezan z višjim tveganjem. Prohaska (2004) omenja pet najbolj uveljavljenih metod analize delnic: sodobna premoženjska teorija, CAPM model (angl. Capital Asset Pricing Model), APT model (angl. Arbitrage Pricing Theory), temeljna (fundamentalna) analiza ter tehnična analiza. Prvo izmed njih je leta 1952 predstavil H. Markowitz (1952), kjer je formaliziral pojma pričakovane stopnje donosa in tveganja. Začetek modela CAPM štejemo z letoma 1964–1965, ko sta izsledke metode določanja učinkovitega portfelja objavila Lintner (1965) in Sharpe (1964). Lintner je že v naslovu dela omenil pojem razpršitev oz. diverzifikacija (angl. diversification), tj. držanje več različnih delnic v enem portfelju z namenom zmanjšanja nesistematičnega tveganja na minimum. Dobrih deset let kasneje je Ross (1976) objavil teorijo cenovne arbitraže oz. model APT, ki je pojmovanje modela CAPM nekoliko razširil. Temeljna analiza se je uveljavila kot standardni postopek znotraj razširjene, tristopenjske analize delnic: Strašek & Jagrič (2008) navajata dva pristopa kombiniranja temeljne analize (mikro raven) s sektorsko analizo (mezzo raven) in ekonomsko analizo (makro raven), tj. od zgoraj navzdol (angl. top-down) ali od spodaj navzgor (angl. bottom-up). Tehnična analiza temelji na grafičnem (tabelaričnem) sledenju preteklega gibanja tečajev in prometa delnic in napovedovanja možnih dogodkov v prihodnost, izvajajo pa jo t. i. čartisti/tehnicisti/mehanicistični investitorji (angl. chartists). Tehnična analiza je najaktualnejša (najakutnejša) od vseh (saj se lahko izvaja v dnevni, urni, minutni, sekundni intervalih, odvisno od dostopnosti podatkov), obenem pa zahteva najmanjši nabor informacij od vseh (praktično le borzne kotacije, ki so večinoma proste dostopne). Temelji na predpostavki, da se vsi faktorji, ki utegnejo vplivati na tečaj, dajo razbrati neposredno iz tečaja (Prohaska, 2004). Tehnična analiza se največkrat uporablja za determiniranje najugodnejšega časa zavzemanja kratkoročnih pozicij znotraj širše (temeljne) analize, lahko pa je, tako kot je predstavljeno v tej raziskavi, tudi glavno orodje za trgovanje.

Mehanski trgovalni sistem je avtomatiziran sestav, ki avtonomno trguje z delnicami (na borzi). MTS sprejema/shranjuje/pridobiva borzne in finančne informacije (kotacije) in te posreduje jedru MTS-a, tj. trgovalni strategiji. Ta na osnovi odločitvenega algoritma oz. kriterija odloči, kdaj kupiti ali prodati katere delnice in tovrstne zahteve pošlje nazaj MTS-u, ki jih po aktualnem tržnem tečaju, zmanjšanem za transakcijske stroške, realizira (v primeru več trgovalnih strategij ostane ogrožje MTS enak). MTS-u je na začetku trgovanja dodeljenih določeno omejeno število prostih denarnih sredstev, s katerimi razpolaga pri trgovanju. V raziskavi s pravimi denarnimi sredstvi ne trgujemo, zato namesto teh MTS-u dodelimo virtualna denarna sredstva, namesto pravega trgovanja pa se poslužimo simuliranega preizkušanja. S tokom časa MTS beleži trgovalne aktivnosti na borzi in končno izdela pripadajoč izpis/vizualizacijo rezultatov. Algoritem 1 prikazuje psevdokod MTS-a.



**Algoritem 1: Mehanski trgovalni sistem**Vhodi: odločitve ITS  $\hat{y}^{(d \times n)}$ , tečajne vrednosti  $tečaj^{(d \times n)}$ ;Izhod: vrednost portfelja  $vp$ ;UVODNO NASTAVI prosta denarna sredstva  $ds^{(1 \times n)}$  na dano vrednost;UVODNO NASTAVI tržno kapitalizacijo  $tk^{(1 \times n)}$  na nič;UVODNO NASTAVI število držanih delnic  $dd^{(1 \times n)}$  na nič;**For** št. trgovalnih dni  $t$  od 2 do  $d$ :

// Nakupni signal		// ponovi za vse dni
$dd\_p^{(1 \times n)} = dd^{(1 \times n)}$ ;		// prepisi prejšnje delnice
$idx^{(1 \times n)} = \hat{y}^{(d \times n)}[t - 1] == 'Kupi'$ ;		// signal za nakup
$cena^{(1 \times m)} = tečaj^{(d \times n)}[t - 1][idx^{(1 \times n)}] \odot r_c$ ;		// popravi za transak. stroške
$temp^{(1 \times m)} = r \left( ds^{(1 \times n)}[idx^{(1 \times n)}] / cena^{(1 \times m)} \right)$		// deljenje elem. z elem.
$dd^{(1 \times n)} = dd^{(1 \times n)} + (z(1 \times n)[idx^{(1 \times n)}] = temp^{(1 \times m)})$ ;		
$cena^{(1 \times n)} = (z(1 \times n)[idx^{(1 \times n)}] = cena^{(1 \times m)})$ ;		
$ds^{(1 \times n)} = ds^{(1 \times n)} - (dd^{(1 \times n)} - dd\_p^{(1 \times n)}) \odot cena^{(1 \times n)}$ ;		
// Prodajni signal		
$dd\_p^{(1 \times n)} = dd^{(1 \times n)}$ ;		
$idx^{(1 \times n)} = \hat{y}^{(d \times n)}[t - 1] == 'Prodaj'$ ;		// signal za prodajo
$dd^{(1 \times n)}[idx^{(1 \times n)}] = 0$ ;		// prodaj delnice
$temp^{(1 \times m)} = tečaj^{(d \times n)}[t - 1][idx^{(1 \times n)}] / r_c$ ;		// deljenje elem. z elem.
$cena^{(1 \times n)} = (z(1 \times n)[idx^{(1 \times n)}] = temp^{(1 \times m)})$ ;		
$ds^{(1 \times n)} = ds^{(1 \times n)} - (dd^{(1 \times n)} - dd\_p^{(1 \times n)}) \odot cena^{(1 \times n)}$ ;		

**EndFor** $tk^{(1 \times n)} = dd^{(1 \times n)} \odot tečaj^{(d \times n)}[d]$ ; $vp = \sum tk^{(1 \times n)} + \sum ds^{(1 \times n)}$ ;

Opombe: Funkcija  $r()$  pomeni zaokroženje na nižjo vrednost (angl. floor), funkcija  $z()$  pa generiranje samih ničel (angl. zeros). Oznaka  $\odot$  označuje množenje elementa z elementom. Programska koda je zaradi hitrejšega izvajanja zapisana vektorsko, tako pa je predstavljen tudi psevdokod.

Transakcijski stroški lahko bistveno vplivajo na uspešnost trgovanja posamezne ITS. So stroški, ki nastanejo pri trgovanju s finančnimi instrumenti. Evans (2012) in Harris (2002) naštevata tri različne tipe transakcijskih stroškov:

- Eksplicitni stroški, med katere po Ullah & Long (2008) spadajo (1) fiksne ali procentualne provizije borznemu posredniku (angl. brokerage fee), (2) provizije borznih hiš, (3) takse, dajatve (angl. stamp duty).
- Implicitni stroški, med katere spadajo (1) razponi med ponudbo in povpraševanjem (angl. bid-ask spread), (2) učinek trga (angl. market impact). Implicitni stroški nastanejo zaradi neposrednega vpliva vlagateljev na tečaj.
- Oportunitetni stroški neuspešnih naložb, ki se pojavijo, če vlagatelj ne trguje dovolj agresivno in posledično ne uspe realizirati nobenih dobičkov.

Rast transakcijskih stroškov negativno vpliva na učinkovitost ekonomije, saj konkretno ostane na voljo manj kapitala za ustvarjanje premoženja. Stroški namreč zmanjšujejo neto dobičke; v kolikor je trgovanje zelo frekventno, se lahko ti zajedajo tudi v kapital. Berk & Green (2005) ugotavljata, da dodatna investicijska vlaganja v vzajemne sklade ne ohranjajo podobnih nivojev dobičkov, saj se aktivni menedžerji srečujejo s padajočo ekonomijo obsega. Edelen idr. (2011) so empirično pokazali, da so eni izmed možnih virov padajoče ekonomije ravno transakcijski stroški. Na podlagi vzorčnih podatkov iz holdinga Morningstar in newyorške borze so avtorji ocenili, da so v letih 1995–2005 transakcijski stroški znašali v grobem 144 baznih točk oz. 1,44 %, in da se je trgovalna dejavnost skladov z relativno majhnimi obsegi trgovanja (angl. trade size) izkazala kot pozitivno korelirana z dobički, medtem ko trgovalna dejavnost skladov z relativno velikimi obsegi trgovanja kot negativno korelirana z dobički. Potemtakem velja, da večji kot so zneski trgovanja, manjši bodo dobički od trgovanja, čeprav moramo upoštevati tudi dejstvo, ki ga poročata Berk & Green (2005), da ima okrog osemdeset odstotkov menedžerjev dovolj znanja in spretnosti, da z aktivnim trgovanjem vsaj povrnejo transakcijske stroške.

Ullah & Long (2008) so izvedli preizkus z aktivnim upravljanjem portfelja, pri čemer so variirali transakcijske stroške od 0 % do 0,5 % in 1 %. Avtorji poročajo, da uvedba transakcijskih stroškov v model bistveno zniža uspešnost portfelja, celo do te mere, da sodeč po  $t$ -statistiki Carhartova alfa  $\alpha$  kot indikator uspešnosti ni več statistično značilno različna od primerjalnega merila. Bistveno torej je, da so transakcijski stroški vselej upoštevani tudi v simulacijah. Podobno F. Wang idr. (2014) obravnavajo učinek transakcijskih stroškov, katere spreminjajo v rangi od 0,1 %, 0,2 % in 0,5 %. Vse vrednosti izračunanih kazalnikov letnega neto dobička (angl. annual net profit, krajše ANP), Sharpeov kvocient in količnik izplačila (angl. payoff ratio) s povečevanjem stroškov upadejo, v najvišji meri se zmanjša tretji. Podobno avtorji ugotovijo, da s povečevanjem transakcijskih stroškov portfelj postaja čedalje bolj konzervativen. Tudi Chiu & Xu (2004) poročajo o bistvenem upadu Sharpeovega kvocienta z uvedbo transakcijskih stroškov. Čeprav avtorji uporabijo nizke procentualne transakcijske stroške pri  $r_c = 0,1$  %, se to bistveno pozna tako pri donosu, kakor tudi tveganju. Presenetljivo se z uvedbo stroškov zmanjšata oba, tako donos, kakor tudi tveganje, kar ima za posledico padec vrednosti Sharpeovega kvocienta. Transakcijske stroške uvedeta tudi Bitvai & Cohn (2015), pri tem pa poročata, da se kot posledica tega neto dobički zmanjšajo, a dodajata, da kljub temu to ni zagotovilo, da bo ITS poslovala slabše od merila.

V sedANJI dobi smo priča padanju transakcijskih stroškov, v največji meri na račun digitalizacije in tehnološkega napredka, ki nam omogoča lažje komuniciranje in boljše dostopnost informacij. To drastično zmanjšuje pomembnost vloge posrednikov, s tem pa tudi njihove kompenzacije. Še posebej se je to pokazalo z (1) masovno rastjo spletnih servisov (npr. eToro, Degiro, E\*Trade, Robinhood ...<sup>10</sup>), s pomočjo katerih lahko vsak posameznik prične trgovati na finančnih trgih in (2) nadomeščanjem človeških virov s strežniškimi računalniki.

---

<sup>10</sup> <https://money.com/best-online-stock-trading/>

## 3.2 Nevronske mreže s povratno zanko

### 3.2.1 Rekurentna nevronska mreža


Rekurentna nevronska mreža (angl. Recurrent Neural Network, krajše RNN) se od običajne vnaprej usmerjene mreže razlikuje po dodani povratni povezavi, kar praktično pomeni, da izhod RNN nastopa tudi kot vhod (Rumelhart et al., 1986). RNN se uvrščajo med dinamične nevronske mreže, zaradi česar so posebej primerne za obdelavo časovnih oz. zaporednih (sekvenčnih) podatkov (Hagan et al., 2014). RNN najdemo v aplikacijah za prepoznavanje govora (Graves et al., 2013), ustvarjanje besedil (Sutskever et al., 2011), modeliranja zaporedij (J. Chung et al., 2014), računalniškega vida (Spoerer et al., 2019) in mnogih drugih. Avtorji poročajo o visoki učinkovitosti in široki uporabnosti RNN za potrebe njihovih aplikacij, omenimo pa naj tudi, da sta Fabbri in Moro RNN uporabila celo za trgovanje delnic Dow-Jones indeksa (Fabbri & Moro, 2018), uspešnost RNN pa, podobno kot Karpathy na svojem blogu<sup>11</sup>, označila kot nerazumno učinkovite.

Posebnost RNN je t. i. odvijanje skozi čas (angl. unfolding through time), čigar proces lahko ponazorimo s sliko 6, povzeto po Goodfellow idr. (2016). Pri tem ne razširjamo posameznega primerka, temveč zaporedje več primerkov. Matematično lahko dinamični sistem RNN zapišemo kot:

$$\mathbf{h}^{(t)} = f(\mathbf{h}^{(t-1)}, \mathbf{x}^{(t)}; \theta),$$

pri čemer  $\mathbf{h}^{(t)}$  predstavlja notranje stanje RNN v časovni enoti  $t$ ,  $\mathbf{h}^{(t-1)}$  pa predstavlja prejšnje notranje stanje RNN. Z  $\mathbf{x}^{(t)}$  označimo posamezni primerek, s  $\theta$  označimo parametre RNN.

Slika 6: Odvijanje RNN skozi čas



Opombe: levi črtkan kvadrat simbolično prikazuje RNN s povratno zanko, desni kvadrat fizično prikazuje, kako se RNN odvija skozi čas (oba dva prikaza sta identična). Pri tem kompleksnost RNN linearno narašča.  $\mathbf{x}$  predstavlja vhodne zaporedne podatke, ki so medsebojno ločene z indeksom ( $t$ ). Postopek razširjanja si sledi kot  $(\mathbf{x}^{(0)}, \dots, \mathbf{x}^{(t-1)}, \mathbf{x}^{(t)}, \mathbf{x}^{(t+1)}, \dots, \mathbf{x}^{(T_s)})$ , pri čemer je  $T_s$  poljubno število.  $\mathbf{h}$  predstavlja notranje stanje RNN (ki se prav tako spreminja skozi čas).

Sodeč po sliki 6 lahko ugotovimo, da RNN hitro postane zelo kompleksna. Zaradi tega so se pri njih uveljavili posebni dinamični učni algoritmi, med enostavnejšimi srečamo vzvratno učenje skozi čas (angl. BackPropagation Through Time, krajše BPTT). Izpeljava učnega postopka BPTT

<sup>11</sup> <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>

je formalizirana v Goodfellow idr. (2016, Poglavlje 10), pri čemer ideja BPTT-ja sloni na razširjanju in naknadnem izračunavanju napake vzratnega razširjanja. V preteklosti so se razvile posebne izvedenke RNN mrež, npr. LSTM (ki bodo predstavljene v naslednjem podpoglavju).

### 3.2.2 Nevronska mreža z dolgim kratkotrajnim spominom

LSTM so primer časovnih (rekurentnih) nevronske mreže s povratno zanko. Proti koncu prejšnjega tisočletja sta jih razvila Hochreiter & Schmidhuber (1997a, 1997b) kot odgovor na dve tipični pomanjkljivosti običajnih rekurentnih mrež: eksplodirajoči in izginjajoči gradient (Hanin, 2018). So namensko ustvarjene za razširjanje zaporednih podatkov in jih najpogosteje najdemo na naslednjih področjih:

- glasovna obdelava (Park et al., 2019), akustično modeliranje (Sak et al., 2014), klasifikacija zvokov (Lezhenin et al., 2019), sinteza zvoka (Zen & Sak, 2015);
- računalniška obdelava slik (Cheng et al., 2016), razpoznavanje sentimenta iz teksta (D. Li & Qian, 2016), semantična kompozicija (Zhu et al., 2016);
- zaznavanje anomalij v dobavni verigi (Tran et al., 2019), kratkotrajno napovedovanje vetrne energije (Qu et al., 2016) in tečaja elektrike (L. Peng et al., 2018), napovedovanje dogajanj na finančnih trgih (Fischer & Krauss, 2018);
- napovedovanje preostale dobe obratovanja (Zheng et al., 2017), zaznavanje zlonamerne programske kode (Vinayakumar et al., 2018), napovedovanje vremena (Zaytar & Amrani, 2016).

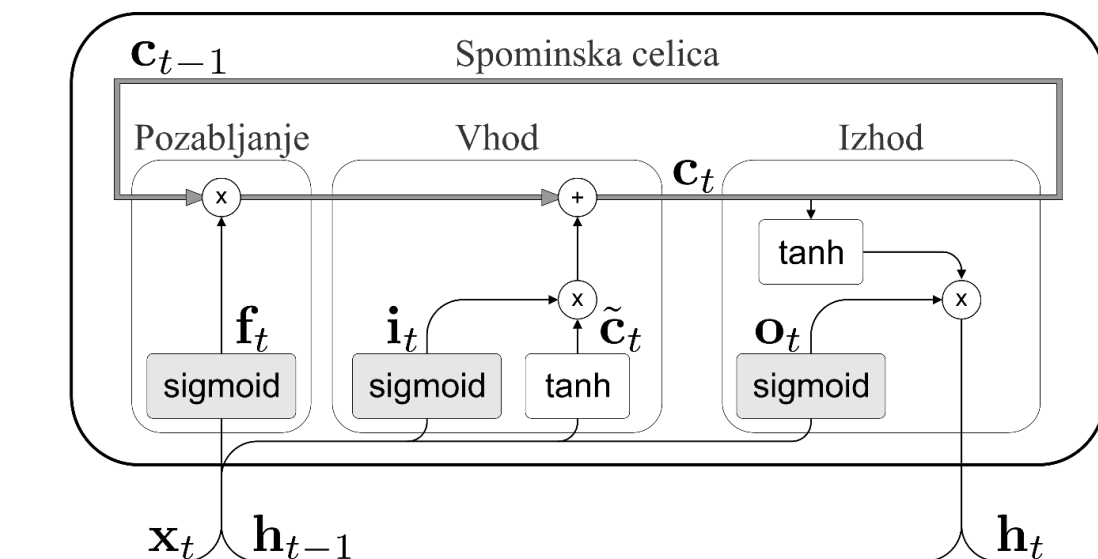
LSTM so vsesplošno uporabne. Van Houdt idr. (2020) so navedli številne druge aplikacije LSTM, pri čemer so njihovo uporabnost uredili v pet večjih skupin: (1) napovedovanje časovnih serij (angl. Time Series Prediction, krajše TSP); (2) obdelava naravnega jezika (angl. Natural Language Processing, krajše NLP); (3) slikovno in video naslavljanje (angl. image and video captioning); (4) računalniški vid (angl. computer vision) in (5) ostalo. Vse aplikacijam je skupno, da je kodiranje vhodnih podatkov urejeno zaporedno.

Splošno rečeno so LSTM orodje za obravnavanje in modeliranje zaporednih podatkov. Na eni strani sprejemajo vhodne zaporedne informacije, npr. dnevne, urne, minutne, sekundne borzne in finančne kotacije, vrednosti tehničnih indikatorjev, vrednosti regresijskih naklonov, ipd., in te nato uporabijo za izgradnjo modela, ki se sproti samostojno posodablja z najnovejšimi informacijami. Tako zgrajeni model sledi dejanskemu toku informacij (npr. stanja na borzi skozi več let) in sproti ugotavlja (zaznava/identificira) vidnejše vzorce (npr. trgovalne vzorce, vzorce ponudbe in povpraševanja). Prednost LSTM pred običajnimi povratnimi je, da si te zapomnijo vidnejše vzorce bistveno dlje časa. Kot vse ostale nevronske mreže se tudi LSTM lahko proaktivno uporabijo za napovedovanje prihodnjih razmer, npr. če mreži podamo najnovejše informacije lahko z razširjanjem teh informacij skozi zgrajen model in ugotovljene vzorce, ki so se pokazali v preteklosti, ugotovimo, kaj LSTM predvideva, da bi se utegnilo zgoditi v bližnji prihodnosti. In če dobimo to informacijo pravočasno (npr. v realnem času), lahko to informacijo izkoristimo, npr. zasedemo določeno pozicijo na borzi.

Zasnova LSTM je kompleksna, zato prikazujemo samo abstraktno zasnovo (slika 7). Osnovni gradnik LSTM je spominska celica, ki informacije iz prejšnjih korakov povratno pripelje na

vhod. Ta spominska celica se s tokom časa posodablja oz. prilagaja vhodnim informacijam. Te so, preden so prikazane spominski celici, filtrirane.

Slika 7: Osnovna zgradba LSTM



Opombe: Razvidna je t. i. spominska celica, ki deluje kot povratna zanka. LSTM sestojijo iz treh vrat, tj. 1) vrat za pozabljanje (nerelevantnih informacij), 2) vhodnih vrat in 3) izhodnih vrat. Prikazani sta dve transformacijski funkciji, tj. sigmoidna (»sigmoid«) in hiperbolični tangens (»tanh«).  $c_{t-1}$  predstavlja vsebnost spominske celice (angl. memory cell) iz prejšnjega koraka, ko se ta posodobi za najnovejše informacije, postane  $c_t$ .  $x_t$  pomeni nove (aktualne) informacije, ki se s pomočjo vhodnih vrat zapišejo v spominsko celico.  $h_{t-1}$  predstavlja skrito plast (angl. hidden state) LSTM v prejšnjem koraku,  $h_t$  v aktualnem.  $f_t, i_t, o_t$  predstavljajo komponento za pozabljanje, vhodno ter izhodno komponento, medtem ko  $\tilde{c}_t$  pomeni »kandidatno« komponento (angl. cell candidate) za vpis v spominsko celico. Vir: D. Fister idr. (2021) in Olah (2015).

Glede na sliko 7 lahko izrazimo naslednje transformacijske enačbe, ki simbolizirajo razširjanje:

$$\begin{aligned}
 i_t &= \sigma(\mathbf{w}_i \cdot \mathbf{x}_t + \mathbf{r}_i \cdot \mathbf{h}_{t-1} + \mathbf{b}_i), \\
 f_t &= \sigma(\mathbf{w}_f \cdot \mathbf{x}_t + \mathbf{r}_f \cdot \mathbf{h}_{t-1} + \mathbf{b}_f), \\
 o_t &= \sigma(\mathbf{w}_o \cdot \mathbf{x}_t + \mathbf{r}_o \cdot \mathbf{h}_{t-1} + \mathbf{b}_o), \\
 \tilde{c}_t &= \tanh(\mathbf{w}_g \cdot \mathbf{x}_t + \mathbf{r}_g \cdot \mathbf{h}_{t-1} + \mathbf{b}_g), \\
 c_t &= i_t \odot \tilde{c}_t + f_t \odot c_{t-1}, \\
 h_t &= o_t \odot \tanh(c_t),
 \end{aligned}$$

kjer s  $\sigma$  označimo sigmoidno transformacijsko funkcijo,  $\odot$  pa pomeni operator množenja elementa z elementom. Pri transformacijskih enačbah vpeljemo tri nove uteži, vhodno (angl. kernel), rekurentno in prag (angl. bias), katerih komponente zapišemo kot:

$$\mathbf{W} = \begin{bmatrix} \mathbf{w}_i \\ \mathbf{w}_f \\ \mathbf{w}_o \\ \mathbf{w}_g \end{bmatrix}, \mathbf{R} = \begin{bmatrix} \mathbf{r}_i \\ \mathbf{r}_f \\ \mathbf{r}_o \\ \mathbf{r}_g \end{bmatrix}, \mathbf{B} = \begin{bmatrix} \mathbf{b}_i \\ \mathbf{b}_f \\ \mathbf{b}_o \\ \mathbf{b}_g \end{bmatrix}.$$

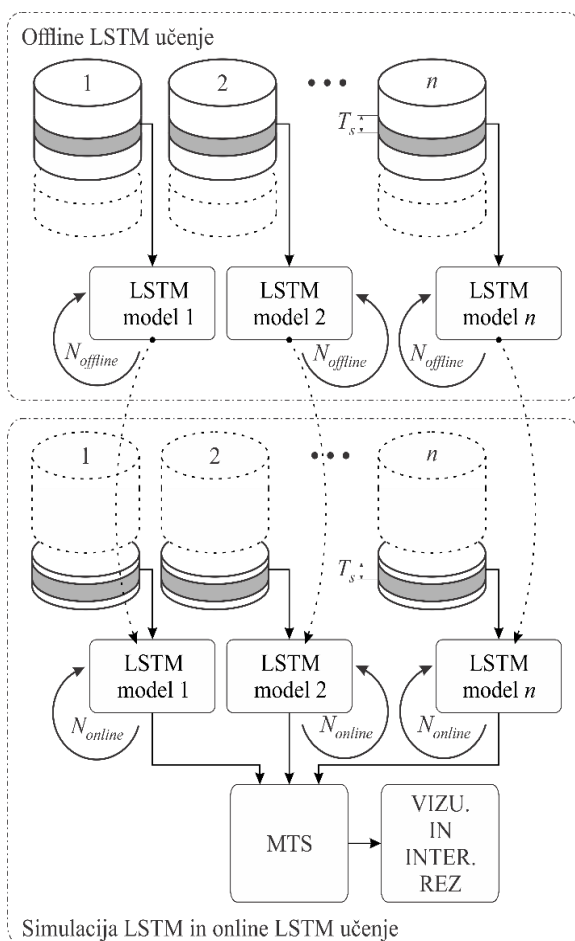
### 3.3 Sinteza LSTM

Naš cilj eksperimentalnega dela LSTM je pokazati, da lahko LSTM uporabljamo za namene trgovanja in da lahko pri tem premagajo klasične trgovalne strategije. Trgovanje z delnicami zastavljamo kot klasifikacijski problem: za določen klasifikacijski primerek v določenem časovnem trenutku želimo določiti najugodnejši trgovalni signal. Študijo izvajamo na vzorcu 27 delniških finančnih instrumentov, pri tem nas zanima, ali med njimi obstajajo podobne karakteristike trgovalnih vzorcev oz. se lastnosti posameznih delnic razlikujejo toliko, da je treba vsako obravnavati posebej. Priredimo dve različni ogroddji:

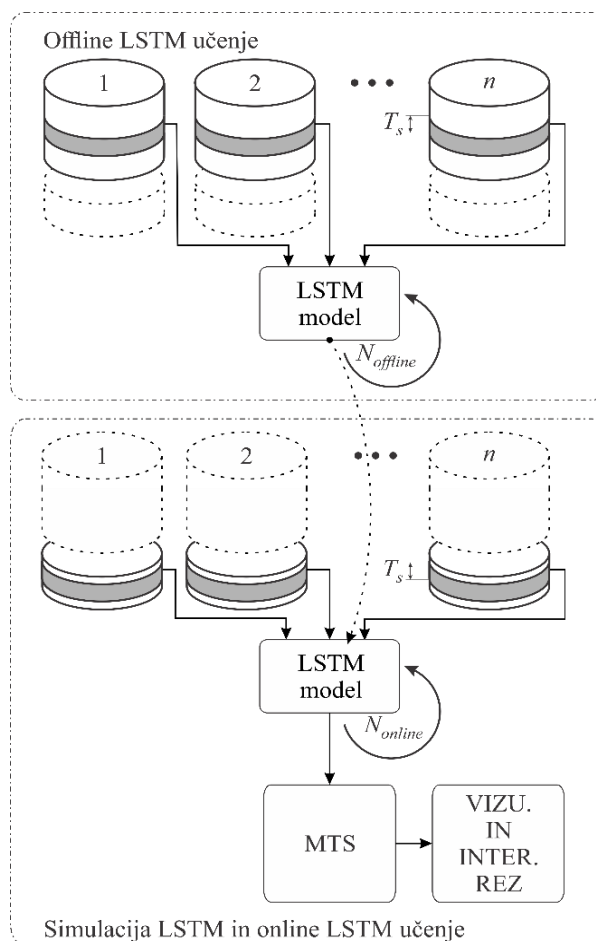
1. Enotni (splošni) model (enotna LSTM ITS), ki vse delnice obravnava enako, brez razlik. Pri tem ogroddju obravnavamo samo en model, ne glede na število vključenih delnic v portfelj. Poudarjena je enostavnost modela, nizka časovna kompleksnost izvajanja, robustnost in primernost izvajanja modela na manj sposobnih sistemih.
2. Posamični model (posamična LSTM ITS), ki vsako delnico obravnava posamično. Tako je za vsako delnico posebej implementiran posamični model, kar pomeni, da je število modelov enako številu delnic v portfelju. Značilnosti posamičnega modela (posamična LSTM ITS) so prilagodljivost, višja kompleksnost in poudarjena variabilnost.

S tovrstnima ogroddjema smo želeli eksperimentalno preizkusiti t. i. modelsko univerzalnost (Ruiz-Cruz, 2018), tj. ali so vzorci metod tehnične analize: trend, odvod, indikatorji, regresije, zamiki, momenti ipd., med različnimi delnicami toliko podobni, da se lahko uporabijo v splošnem, ali pa prihaja pri trgovalnih vzorcih določenih delnic do bistvenih razlik. Ozadje obeh ogroddij cilja na fenomen psihološkega nagona, panike, brezna, ipd., ki pravzaprav delujejo na vlagatelje zelo podobno, tudi če ti trgujejo z različnimi delnicami. Na podobnost vzorcev odločilno vpliva tudi sistematično tveganje, npr. večje kot je sistematično tveganje, večja je verjetnost, da bo vlagatelj opravljal podobne vzorce, in obratno. Sirignano & Cont (2018) omenjata univerzalne značilnosti formiranja tečaja na finančnih trgih. Wilson (1994) je poročal, da je lahko en kaotični model uporaben za trgovanje na stotine delnic, skozi daljše časovno obdobje, brez sistemskih sprememb modela. Sezer & Ozbayoglu (2018) sta izvedla analizo trgovanja z uporabo splošnega (enotnega) modela konvolucijske nevronske mreže na primeru 30 delnic ameriškega Dow-Jones indeksa, pri čemer so eksperimenti pokazali potencial ideje o univerzalnosti za naprej. Po drugi strani so Chihab idr. (2019) eksplicitno zapisali, da noben skupni model ne more predvideti za vse delnice naenkrat, kaj se utegne zgoditi (ta zamisel je bila v preteklosti formalizirana pod besedno zvezo nič ni zastonj, angl. no-free-lunch-theorem). Na borzi se dogaja marsikaj, tudi borzne anomalije (skupne vlagateljem), kot so špekulacije, čredni nagon, magično mišljenje, nepomembnost preteklosti, pohlep, čustveni naboj, prekomerno zaupanje in podobne. In logično pri tem je, da te anomalije v večji ali manjši meri vplivajo na vse delnice hkrati. Sliki 8 in 9 prikazujeta obe predlagani ogroddji grafično.

Slika 8: Posamični LSTM-model



Slika 9: Enotni LSTM-model



Opombe: »Vizu. in Inter. Rez« pomeni vizualizacija in interpretacija rezultatov.

Vir: D. Fister idr. (2021).

Vsaka posamezna slika je razdeljena v dva okvirja: spodnjega in zgornjega. Zgornji okvir predstavlja postopek občega (angl. offline) LSTM učenja (posamičnih modelov ali skupnega), medtem ko spodnji okvir simulacijo (napovedovanje) LSTM in naknadno sprotno (angl. online) LSTM učenje. Število ponovitev učenja (število epoh) je pri občem učenju enako  $N_{offline}$  pri sprotnem  $N_{online}$ . Pri občem učenju se zaradi nepristranskosti uporablja le učni vzorec (označen z debelo črno črto); pri napovedovanju in sprotnem učenju le testni (z debelo črno črto je označen aktualni vzorec). Temno šrafiran del zbirke podatkov, tako učne kot testne, predstavlja posamezni primerek dolžine  $T_s$  (ta primerek dejansko vključuje več zaporedno sestavljenih primerkov; spomnimo, da LSTM zahteva zaporedne podatke). Sprva poteka obče učenje (na učnem vzorcu), ki se mora pred nadaljevanjem v celoti zaključiti. Ko je slednje zaključeno, se zgrajen model izmenjaje uporabi za napovedovanje (na testnem vzorcu) in sprotno učenje. Zvezo simbolično prikazuje vertikalna črtna puščica. Namen sprotnega učenja je posodobiti trenutni model sedanjim razmeram (najnovejšim informacijam). Končno je izvedena tudi vizualizacija rezultatov.

### 3.3.1 Odvisna spremenljivka

Odvisno spremenljivko, ki je uporabljena pri učenju LSTM, tvorimo kot kvocient med aktualnim zaključnim tečajem in  $n$ -prejšnjim zaključnim tečajem, zmanjšanim za 1:

$$\Delta_n = \frac{x_t^{(close)}}{x_{t-n}^{(close)}} - 1,$$

kjer je  $n$ -dnevna sprememba v tečajih označena z  $\Delta_n$ . V kolikor ta sprememba presega (pozitivni/negativni) *prag*, to ustrezno vpliva na vrednost (klasifikacijski razred) odvisne spremenljivke. Uvedli smo tri najosnovnejše relacije, ki jih lahko generira model in sledijo pojmovanju MTS-a, tj. kupi, zadrži in prodaj:

$$y_t^{(n)} \begin{cases} \text{Kupi;} & \Delta_n \geq \text{prag} \\ \text{Zadrži;} & -\text{prag} < \Delta_n < \text{prag}, \\ \text{Prodaj;} & \Delta_n < -\text{prag} \end{cases}$$

pri čemer je vrednost *prag* nastavljen parameter, čigar vrednost zavisi od eksperimentiranja. Višja kot je vrednost *prag*, tem manj bo učnih signalov za trgovanje ter proporcionalno več za držanje. Nižji kot bo *prag*, tem manj bo učnih signalov za držanje, kar bo pomenilo intenzivno trgovanje in posledično visoke transakcijske stroške. D. Fister, Mun, idr. (2019) so poročali o vrednosti *prag* = 0,05, medtem ko D. Fister idr. (2021) *prag* = 0,035.

### 3.3.2 Učni algoritem Adam

V eksperimentih smo uporabili znan učni algoritem Adam (angl. adaptive moment estimation) avtorjev Kingma & Ba (2015). Adam je predstavnik novejših učnih algoritmov in je prilagojen za optimizacijo stohastičnih funkcij. Temelji na izračunu gradienta prvega reda, kar lahko formaliziramo kot (Kingma & Ba, 2015):

$$\mathbf{g}_t = \nabla_{\theta} f_t(\boldsymbol{\theta}_{t-1}),$$

pri čemer  $\mathbf{g}_t$  predstavlja izračunane gradiente,  $f_t$  je stohastična funkcija,  $\boldsymbol{\theta}_t$  pa prikazuje vektor parametrov (uteži) v časovni enoti  $t$ . Nadalje sta ocenjena prvi in drugi pristranski moment ( $\mathbf{m}_t$  in  $\mathbf{v}_t$ ), katera avtorja oblikujeta kot:

$$\mathbf{m}_t = \beta_1 \cdot \mathbf{m}_{t-1} + (1 - \beta_1) \cdot \mathbf{g}_t,$$

$$\mathbf{v}_t = \beta_2 \cdot \mathbf{v}_{t-1} + (1 - \beta_2) \cdot \mathbf{g}_t^2,$$

kjer  $\beta_1$  in  $\beta_2$  predstavljata nadzorna parametra v rangi  $[0,1)$ , ki s povečevanjem časovne enote  $t$  eksponentno upadata. Prvi in drugi moment predstavljata ocenjene gibajoče povprečje (prvi moment) ter varianco (drugi moment) gradientov. Velja omeniti, da je kvadrat  $\mathbf{g}_t^2$  izračunan kot produkt elementa z elementom ( $\mathbf{g}_t \odot \mathbf{g}_t$ ). Nadalje sta izračunana nepristranska momenta, kot sledi:

$$\hat{\mathbf{m}}_t = \frac{\mathbf{m}_t}{1 - \beta_1^t},$$

$$\hat{\mathbf{v}}_t = \frac{\mathbf{v}_t}{1 - \beta_2^t}.$$

Končno je izračunan popravek (angl. update), kot sledi:



$$\theta_t = \theta_{t-1} - \alpha \cdot \frac{\hat{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{v}}_t + \epsilon}}$$

kjer je  $\epsilon$  prav tako krmilni parameter (konstanta za numerično stabilnost<sup>12</sup>),  $\alpha$  pa predstavlja koeficient učenja (angl. learning rate).

Učni algoritem Adam je zelo priljubljen med raziskovalci, saj ga gre enostavno implementirati, prav tako pa niti časovno, niti resursno potraten. V splošnem združuje pozitivne značilnosti algoritmov AdaGrad in RMSProp, avtorji pa hvalijo tudi intuitivnost algoritma Adam. Že v sami osnovi je bil implementiran na problemih logistične regresije, kakor tudi večplastnih ter konvolucijskih nevronske mreže (Kingma & Ba, 2015).


Podrobnejši potek modeliranja in napovedovanja obeh LSTM ogrodij prikazuje Algoritem 2. Celotni primerek od  $\mathbf{x}_{t-T_s}$  do  $\mathbf{x}_t$  ( $m \times T_s$ ) zaradi načina razširjanja LSTM oblikujemo zaporedno, pri čemer  $m$  pomeni število spremenljivk v vzorcu,  $T_s$  pa dolžino zaporedja. V vsaki časovni periodi LSTM-u razširjamo natanko eno opazovanje (en element primerka), zato je razširjanje celotnega primerka od  $\mathbf{x}_{t-T_s}$  do  $\mathbf{x}_t$  iterativni postopek (slika 10). Razvit model je zato podoben sistemu »več-k-enemu« (angl. many-to-one), pri čemer je na levi strani najstarejše opazovanje  $T_s$  časovnih period nazaj, za slednjim si zaporedno sledijo novejša opazovanja. Najnovejše opazovanje ( $\mathbf{x}_t$ ) je razširjano zadnje. Rezultat razširjanja primerka s pomočjo goste nevronske plasti s softmax aktivacijsko funkcijo pretvorimo v natanko enega izmed klasifikacijskih razredov (kupi, zadrži, prodaj).

<b>Algoritem 2: trgovalna strategija LSTM</b>	
NALOŽI razširjeno zbirko $\mathbf{X}'$ ;	
RAZCEPI razširjeno zbirko $\mathbf{X}'$ v učni in testni vzorec;	
DOLOČI učno konstanto $\alpha$ in njen upad (angl. decay) skozi čas;	
<b>For</b> št. <i>offline epoch</i> učenja:	// št. offline epoch
UČENJE LSTM na <i>učnem</i> vzorcu;	// obče LSTM učenje
<b>EndFor</b>	
UVODNO NASTAVI prazni vektor <i>backtest_vektor</i> ;	
DOLOČI fiksno učno konstanto $\alpha$ ;	
<b>For</b> št. <i>učnih</i> primerkov:	
SESTAVI najnovejši primerek $\mathbf{x}_t$ ;	
$\hat{y}_t =$ NAPOVEJ ( $\mathbf{x}_{t-T_s}$ do $\mathbf{x}_t$ );	// LSTM simulacija
<i>backtest_vektor</i> = RAZŠIRI s $\hat{y}_t$ ;	// shrani napoved
IZRAČUNAJ dejanski $y_t$ ;	// dejansko stanje
<b>For</b> št. <i>online epoch</i> učenja:	
RETRAIN modela z najnovejšim $\mathbf{x}_t$ in $y_t$ ;	// sprotno LSTM učenje
<b>EndFor</b>	
<b>EndFor</b>	
SIMULIRAJ_MTS( <i>backtest_vektor</i> );	// simuliraj dejansko realno-časovno trgovanje
POROČAJ rezultate;	

Vir: D. Fister idr. (2021).

<sup>12</sup> <https://keras.io/api/optimizers/adam/>

Slika 10: Razširjanje primerka od  $\mathbf{x}_{t-T_s}$  do  $\mathbf{x}_t$



Opombe: Borzne in finančne podatke razdelimo v zaporedje z dolžino  $T_s$  in razširjamo element po elementu. Tekom razširjanja LSTM oblikuje spomin. Ob koncu razširjanja zaporedja model vrne napovedno vrednost  $\hat{y}_t$  (možne vrednosti kupi, zadrži, prodaj), ki jo nato pošlje MTS-u. Pri učenju LSTM se napovedna vrednost  $\hat{y}_t$  primerja z znanim dejanskim signalom, razlika med njima pa predstavlja učni signal. Naj spomnimo, da so vhodne veličine ( $\mathbf{x}_{t-T_s}, \mathbf{x}_{t-T_s+1}, \dots, \mathbf{x}_{t-2}, \mathbf{x}_{t-1}, \mathbf{x}_t$ ) vektorji in ne skalarji. Potek  $\mathbf{c}_{t=0}$  do  $\mathbf{c}_{t=T_s}$  prikazuje, kako se v odvisnosti od opazovanj spreminja/prilagaja spominska celica.

Vir: D. Fister idr. (2021).

### 3.4 Eksperimenti

Cilji eksperimentalnega dela z LSTM so bili preizkusiti veljavnost/smiselnost predpostavljene teze in hipoteze H1. V skladu s tem smo pridobili ustrezne borzne in finančne podatke ter zbrano zbirko podatkov razširili z omenjenimi tehničnimi indikatorji. Glede na pregledano literaturo smo določili upravljanje s transakcijskimi stroški. Nadalje smo implementirali LSTM-učenje (obče in sprotno) ter LSTM-napovedovanje (sprotno). Kakovost delovanja LSTM trgovalne strategije smo preverili s simuliranjem trgovanjem na MTS (temu je bilo dodeljenih določeno število prostih denarnih sredstev) ter pridobljene rezultate primerjali s klasičnimi trgovalnimi strategijami. Končno smo izvedli vizualizacijo rezultatov ter podrobno analizo. V splošnem smo za vsako izmed 27 delnic za vsakega izmed predlaganih 2 ogrodij trgovanja (enotni, posamični), izvedli 10 simulacij (vrednost 10 sledi duhu navzkrižne validacije z desetimi rezi, angl. 10-fold cross validation). Te smo nato ovrednotili s pomočjo treh eksperimentalnih preizkusov:

1. preizkus koncepta,
2. preizkus robustnosti,
3. detajlna analiza trgovanja.

Eksperimenti so bili implementirani v programskem jeziku Python<sup>13</sup>. Pri tem smo uporabili sledeče knjižnice (module): pandas-datareader<sup>14</sup> (za komunikacijo z Yahoo Finance), pandas<sup>15</sup>,

<sup>13</sup> <https://www.python.org/>

<sup>14</sup> <https://pandas-datareader.readthedocs.io/en/latest/>

<sup>15</sup> <https://pandas.pydata.org/>

numpy<sup>16</sup> in talib (za obravnavo z originalno zbirko podatkov **X**), keras in Tensorflow za implementacijo LSTM nevronskega modela ter matplotlib za vizualizacijo. Celotna nevronska mreža je bila zastavljena kot dvoslojna mreža, tj. plast LSTM v prvem sloju in gosta (angl. dense) plast s tremi zunanji nevroni (kupi, zadrži, prodaj) v drugem sloju. Nadzorne parametre smo določili, kot prikazuje tabela 5.

Posebno pozornost je iz dveh razlogov zahtevala nastavitve praga (*prag*). Ugotovili smo, da večja vrednost spremenljivke *prag* povzroči manj učnih signalov tipa kupi ali prodaj in obratno. V primeru prenizke nastavitve bodo tako signali tipa kupi in prodaj v večini, kar bo naknadno pomenilo veliko trgovalno aktivnost in posledično visoke izgube zaradi transakcijskih stroškov. V primeru prenizke nastavitve se bo zgodilo ravno obratno, takrat signalov tipa kupi in prodaj ne bo, ali bodo v manjšini, kar bo pomenilo, da model ne bo sposoben reagirati na borzna dogajanja. Drugi razlog je uteženost (simetričnost) signalov tipa kupi in prodaj. Pomembno je namreč, da je zveza med učnimi signali tipa kupi in prodaj ne glede na vrednost spremenljivke *prag* približno utežena. Če izberemo vrednost *prag*, ki nam podaja trikrat večjo zastopanost signalov prodaj, bo to pomenilo določeno stopnjo nesimetričnosti med klasifikacijskimi razredi, kar lahko posledično vpliva tudi na zmožnosti napovedovanja modela. Praktično to pomeni, da bo model bolj nagnjen k enemu ekstremu, npr. prodajanju, kot nakupovanju, kar bo posledično pomenilo krajše pozicije, kot bi si želeli oz. obratno. Končno nastavitve spremenljivke *prag* smo sprejeli eksperimentalno, po vzoru D. Fister idr. (2021). Testni vzorec in s tem testna perioda je bila nastavljena na 33,33 % in je bila daljša od standardne prakse (ki znaša po vzoru 10-razredne prečne validacije 10 %) z namenom zagotoviti bolj rigorozno statistično analizo. Oba vzorca, tako učni kakor tudi testni, sta bila zaradi lastnosti nevronske mreže normalizirana v intervalu [0,1].

Tabela 5: Nadzorni parametri LSTM

Nastavitev	Oznaka	Vrednost
Št. enot LSTM		100
Učni algoritem		Adam
Prag	<i>prag</i>	0,035
Št. offline epoh	$N_{offline}$	200
Št. online epoh	$N_{online}$	10
Offline (padajoča) učna konst.	$\epsilon$	0,002
Online (fiksna) učna konst.		0,001
Časovni horizont	$n$	1
Dolžina zaporedja (časovni koraki)	$T_s$	32
Št. zunanjih nevronov		3
Aktivacijska funkcija*		softmax
Cepitev zbirke podatkov		66,66 % - 33,33 %
Velikost učnega vzorca		1717
Velikost testnega vzorca		843
Transakcijski stroški		1 %
Začetna prosta denarna sredstva		10.000,00 Eur
Št. delnic v portfelju	$k$	27

<sup>16</sup> <https://numpy.org/>

Nastavitev	Oznaka	Vrednost
Št. neodvisnih zagonov	$N$	10
Št. spremenljivk	$m$	43

Opombe: padajoča (spreminjajoča se) učna konstantna je bila definirana kot  $\epsilon \cdot 0,1 \cdot e^{i/N_{offline}}$ , kjer  $i$  predstavlja trenutno (offline) epoho. Glede na to, da zapisana enačba zagotavlja eksponentno padanje vrednosti učne konstante, smo začetno vrednost učne konstante  $\epsilon$  podvojili glede priporočila knjižnice keras (pri online učenju smo to nastavili, kot veleva priporočilo). Časovni horizont je bil izbran kot  $n = 1$ , kar pomeni, da smo pri odvisni spremenljivki izračunavali enodnevne donose. Učni algoritem Adam smo izbrali kot ugodno kombinacijo med učnima algoritmoma AdaGrad in RMSProp. »\*«=se nanaša na zunanje nevrone. Število epoh učenja, tako offline kot online, smo ugotavljali eksperimentalno. Slednje je proti prvemu nastavljenemu relativno nizko, a velja omeniti, da se to izvaja vsak dan znova, kar na dolgi rok pomeni ogromno število epoh. Dolžina zaporedja  $T_s = 32$  je bila ugotovljena eksperimentalno kot kompromis med kratkotrajno stohastičnostjo (variabilnostjo) in dolgotrajno stabilnostjo (trendom/momentom).

### 3.4.1 Merila za ocenjevanje kakovosti trgovalnih strategij

Najosnovnejši merili za ocenjevanje kakovosti trgovalnih strategij sta vmesna in končna vrednost portfelja. Ti dve sta sestavljeni iz skupne vrednosti tržne kapitalizacije in ostanka prostih denarnih sredstev (vsake izmed delnic), ki jih MTS drži v portfelju, npr. če je za določeno delnico na koncu (določen dan oz. zadnji dan trgovalne periode) 100 Eur prostih denarnih sredstev, MTS pa dodatno drži 12,000 Eur tržne kapitalizacije, to pomeni (vmesno ali končno) vrednost 12,100 Eur (za to delnico). Posledično je skupna vrednost portfelja izračunana na osnovi vseh delnic v portfelju. Vmesna in končna vrednost portfelja sta glede primerjave s klasičnimi trgovalnimi strategijami najpomembnejši, zato slednjima posvečamo največjo pozornost. Na to temo izvedemo eksperimentalni test – preizkus koncepta. Dodatno izvedemo tudi preizkus robustnosti, pri čemer smo podrobneje pozorni na variabilnost trgovanja. Natančnejšo statistično analizo izvedemo v detajlni analizi. Tam na osnovi vrednosti portfelja za vsako trgovalno strategijo izrazimo končne vrednosti portfeljev, donos in finančno beto, dodatno pa podamo tudi število menjav vsake trgovalne strategije in standardne finančne kazalnike, ki jih je moč izračunati na osnovi podatkov trgovanja: Sharpeov kvocient, Jensenovo alfo in Treynorjev kvocient. Finančno beto določimo kot:

$$\beta_{iM} = \frac{\text{Cov}(r_i, r_m)}{\text{Var}(r_m)},$$

pri čemer  $r_i$  in  $r_m$  pomenita enodnevne donose posamezne ITS in tržne (angl. market) donose, tj. enodnevne donose delniškega indeksa DAX30 (ki nastopa kot primerjalna letvica/merilo, angl. benchmark). Vrednost finančne bete  $\beta = 1$  bo pomenila enako tvegano naložbo, kot če bi razpršeno vložili v vse delnice indeksa DAX30. Vrednost finančne bete  $\beta < 1$  bo pomenilo manjše relativno tveganje glede na primerjalno merilo, medtem ko vrednost bete  $\beta > 1$  višje relativno tveganje glede na primerjalno merilo. Naslednji detajlni indikator, tj. Sharpeov kvocient izračunamo kot:

$$S_a = \sqrt{N} \cdot \frac{\mathbf{E}(\mathbf{r}_i - \mathbf{r}_m)}{\sqrt{\text{Var}(\mathbf{r}_i - \mathbf{r}_m)}}$$

kjer  $N$  predstavlja število trgovalnih dni v letu, predpostavimo  $N = 252$ , funkcija  $\mathbf{E}(\mathbf{r}_i - \mathbf{r}_m)$  pa predstavlja matematično upanje med razlikami enodnevnih donosov posamezne trgovalne strategije in enodnevnih donosov trga (opozarjamo, da sta to vektorja). Negativne vrednosti

Sharpeovega kvocienta nakazujejo na dejstvo, da bodo donosi trga višji od trgovalne strategije (kar je slabo); pozitivne vrednosti pričajo, da so donosi trgovalne strategije višji od trga; vrednosti v okolici ničle signalizirajo, da se donosi ne razlikujejo bistveno. Če predpostavimo, da je  $\sqrt{N}$  konstanta, potem višja varianca razlik med donosi posamezne ITS in trga povzroči manjšo vrednost Sharpeovega kvocienta (kar je slabo); manjša varianca po drugi strani povzroči višjo vrednost Sharpeovega kvocienta. Podobno izračunamo tudi Jensenovo alfo (ta je odvisna od finančne bete):

$$\alpha_J = R_i - \left( R_f + \beta_{iM} \cdot (R_m - R_f) \right),$$

pri čemer  $R_f$  označuje netvegano obrestno mero (angl. risk free interest rate, predpostavimo  $R_f = 2\%$ ),  $R_i, R_m$  pa sta končni donosnosti (skalarja) posamezne ITS in trga (za razliko od enodnevnih donosov  $\mathbf{r}_i, \mathbf{r}_m$ , ki sta vektorja). Velja opozoriti, da je člen znotraj zunanlega oklepaja CAPM model. Pozitivne vrednosti (oz. relativno višje vrednosti) Jensenove alfe pričajo o relativno višji učinkovitosti ITS glede na trg, medtem ko negativne vrednosti (oz. relativno nižje vrednosti) o slabši učinkovitosti. Končno izpostavimo tudi Treynorjev koeficient:


$$T = \frac{R_i - R_f}{\beta_{iM}},$$

Višja vrednost števca priča o višji razliki med končnim donosom posamezne ITS in trgom, kar je ugodno; višja finančna beta  $\beta_{iM}$  zmanjšuje vrednost Treynorjevega koeficienta  $T$  (kar je slabo). Zasedujemo torej višje vrednosti koeficientov predlaganih LSTM ITS. Vse navedene indikatorje bomo obravnavali v sklopu detajlne statistične analize.

### 3.4.2 Preizkus koncepta

Preizkus koncepta je bil prvi izmed eksperimentalnih testov kakovosti delovanja trgovalnih strategij. Pri tem testu smo iz desetih neodvisnih preizkusov obeh predlaganih pristopov (tako enotnega kot posamičnega) izlučili najboljše glede na končno vrednost portfelja ter rezultate grafično vizualizirali. Dodatno smo kot primerjavo obema pristopoma LSTM vizualizirali tudi klasične trgovalne strategije (pasivno, RSI, MACD). Rezultate preizkusa koncepta prikazuje slika 11.

Slika 11: Potek trgovanja LSTM ITS



Opombe: Nastavitve RSI sledijo priporočilom spletne strani Investopedia<sup>17</sup> in so enake 30 za spodnjo mejo, 70 za zgornjo. Nastavitve MACD – negativne vrednosti MACD histograma pomenijo prodajo, pozitivne vrednosti nakup. »LSTM1« pomeni posamično LSTM ITS, »LSTM2« enotno LSTM ITS. Črtkana črta prikazuje začetno vrednost portfelja, tj. 270 tisoč Eur prostih denarnih sredstev. LSTM1 ITS doseže najvišji končni donos, sledi LSTM2 ITS, pasivna ITS ter RSI ITS. Najnižji končni (in vmesni) donos vseh dosegajo MACD ITS. Večino trgovanih dni (do malo pred koncem trgovanja) je v prednosti pasivna ITS (obdobje bikovskega trenda), a ta v zadnjih mesecih trgovanja drastično izgubi na vrednosti. Hitro zatem se pojavi obdobje kratkotrajnega okrevanja in nova možnost za plemenjenje portfelja. LSTM1, LSTM2, RSI in MACD uspejo izgubo limitirati, pri tem je najuspešnejša LSTM1, ki kmalu po črnih dneh vrednost portfelja celo doda, ostalim (LSTM2, RSI, MACD) pa je skupno, da dodatne vrednosti portfelja v obdobju okrevanja ne uspejo realizirati. Vir: D. Fister idr. (2021).

Četudi posamična LSTM ITS doseže bistveno višji donos kot vse ostale ITS, bode v oči dejstvo, da večino časa zaostaja za pasivno klasično ITS. Ugotavljamo, da so največje prednosti posamične LSTM ITS v primerjavi z ostalimi hitre reakcije s prodajanjem instrumentov v medvedjih časih. V času pandemične krize vmesna vrednost portfelja pasivne ITS močno upade, pri posamični LSTM ITS le malo. Smatramo, da je posamična LSTM ITS potemtakem bolj primerna za omejevanje izgub ob kriznih časih kakor za izkoriščanje možnosti za plemenjenje portfeljske vrednosti. Nenazadnje od implementiranih ITS nikoli ne zahtevamo, da izkoristijo vse možnosti za povečanje donosa, temveč le, da na dolgi rok v povprečju ohranjajo začetni vloženi znesek in občasno izkoristijo bikovski trend za plemenjenje portfelja. Enotna LSTM ITS prav tako kot njeno predhodnica uspe v večji meri ohraniti vloženi začetni znesek (in premagati pasivno kupi-in-zadrži ITS), a je končni donos veliko manjši oz. celo negativen glede na vložena sredstva. Tudi nestanovitnost (angl. volatility) slednje je nekoliko manjša od nestanovitnosti posamične LSTM ITS in bistveno manjša od nestanovitnosti pasivne ITS. Ugotavljamo, da obe predlagani ITS v povprečju delujeta kot filter – pri naraščanju pasivnega indeksa naraščata tudi vrednosti vmesne posamične in enotne LSTM ITS in obratno,

<sup>17</sup> <https://www.investopedia.com/terms/r/rsi.asp>

a je pri tem enotna LSTM ITS manj uspešna. Pasivna ITS, ki je obarvana popolnoma črno, doseže najvišjo končno vrednost portfelja od celotnega nabora primerljivih ITS. Čeprav je ta podvržena najvišji stopnji nestanovitnosti, končno trgovanje zaključi le z malenkostno negativnim izkupičkom. RSI ITS deluje le za spoznanje slabše glede na končno vrednost portfelja, delno tudi zaradi dejstva, da zamudi okrevanje po prvem valu pandemije. V tem času se trgovanje z RSI ITS sodeč po grafikonu popolnoma zaustavi, kar nakazuje horizontalna črta. Ne glede na okrevanje dosega RSI ITS večino druge polovice trgovanja, ko na trgu prevladuje okrevanje, vrednosti pod vloženim zneskom. Trgovanje z MACD ITS na borzi sodeč na vzorčnih podatkih ni primerno. MACD ITS ne izkazuje nobenih donosov, delno tudi zaradi visoke frekvence trgovanja. Skupna vrednost portfelja upada oz. stagnira skozi celotno trgovalno obdobje. Ugotavljamo, da je metoda MACD zelo primerna in razširjena za natančno tempiranje zavzemanja trgovalnih pozicij, ni pa primerna kot samostojna ITS.

### 3.4.3 Preizkus robustnosti

Preizkus robustnosti je bil izveden za enotni in posamični model na osnovi vseh deset opravljenih zagonov. S preizkusom robustnosti preverjamo, kako zelo se končne vrednosti portfelja med različnimi zagoni razlikujejo (kako zelo robustni so); upoštevamo le končne vrednosti portfeljev (v nasprotju s preizkusom koncepta, kjer smo preverili celotno trgovalno obdobje). Za vsako izmed delnic izračunamo maksimalno, minimalno ter srednjo končno vrednost portfelja, tj. vrednost, katero ima posamezna trgovalna strategija na zadnji trgovalni dan. Naknadno izračunamo razpon med najnižjo in najvišjo vrednostjo končnega portfelja, kar predstavlja razmik oz. robustnost; višji kot je razmik, manjša je robustnost in obratno. Za vsako delnico v portfelju glede na začetna vložena sredstva izračunamo tudi maksimalni donos. Za lažjo primerjavo dodamo tudi izračunano razliko ( $\Delta$ ) med srednjima vrednostma enotnega in posamičnega modela (tabela 6).

Za naslednjih enajst delnic opazimo bistvene razlike med srednjimi vrednostmi obeh modelov (razlike  $\Delta$  večje od 1000 Eur): ADS.DE, BAYN.DE, BMW.DE, CON.DE, DB1.DE, EOAN.DE, FME.DE, FRE.DE, HEN3.DE, MTX.F, VOW3.DE. Za štiri izmed teh je višja vrednost posamičnega modela, za ostale enotnega. Izpeljemo, da enotni model v povprečju dosega bistveno boljše rezultate. Rezultat je nekoliko presenetljiv, saj smo pričakovali, da bo prikrojenost posamičnega modela za vsako delnico prinesla najugodnejše rezultate. Ugotavljamo, da prikrojenost dejansko prinese najugodnejše rezultate, če rezultate opazujemo posamično (s preizkusom koncepta), medtem ko gledano v povprečju zaradi nižje robustnosti (ali višje stohastičnosti) rezultati močno upadejo. Če primerjamo srednje vrednosti za celotni portfelj (ne samo na osnovi posameznih delnic), ugotavljamo, da vsota srednjih vrednosti enotnega modela znaša 245.300,59 Eur, vsota srednjih vrednosti posamičnega modela pa 247.648,17 Eur. Iz ugotovljenega sklepamo, da med enotnim in posamičnim modelom v povprečju ne prihaja do bistvenih razlik, kar pomeni, da sta si modela v povprečju enakovredna. Dodatno ugotovimo, da srednja vrednost razlik  $\Delta$  znaša 228,47 Eur, kar glede na začetna vložena denarna sredstva ni bistveno. To sta pomembni vsebinski ugotovitvi, ki zahtevata dodatno razlago.

Enakovrednost enotnega in posamičnega modela pomeni, da lahko z enim splošnim trgovalnim modelom, ki pokrije cel spekter finančnih instrumentov, dosegamo podobne trgovalne izide kot z za vsak finančni instrument posamičnim modelom. Posledično to pomeni, da so trgovalni vzorci na borzi v povprečju na obsegu vzorčenih 27 delnic enakovredni

(podobni). Vlagatelji so potemtakem nagnjeni k podobnemu obnašanju na borzi. In če je obnašanje podobno, pomeni, da na borzi obstajajo splošni (univerzalni) psihološki učinki ki jih lahko označimo pod pojmom univerzalni gonilniki tečajev. Kar je pri tem pomembno je, da se ti splošni psihološki učinki dajo identificirati (Heath et al., 1999; Huddart et al., 2007; Knauff et al., 2010).

Tabela 6: Preizkus robustnosti med enotnim in posamičnim modelom. Število zagonov  $N = 10$

	Enotni model				Posamični model				$\Delta$
	max	min	sred	max. donos	max	min	sred	max. donos	
ADS.DE	15.845,50	8.372,44	12.450,76	5.845,50	11.385,29	8.135,82	9.326,09	1.385,29	-3.124,67
ALV.DE	12.271,80	9.903,88	11.282,14	2.271,80	11.765,34	10.087,04	10.681,49	1.765,34	-600,65
BAS.DE	7.104,99	3.053,42	5.081,94	-2.895,01	6.963,76	4.202,84	5.075,23	-3.036,24	-6,71
BAYN.DE	7.808,00	4.850,70	5.921,02	-2.192,00	8.962,23	5.479,92	7.122,02	-1.037,77	1.201,00
BEI.DE	10.821,01	7.824,75	9.482,37	821,01	9.516,12	8.167,38	8.969,41	-483,88	-512,96
BMW.DE	5.826,42	4.438,61	5.363,15	-4.173,58	11.862,33	5.112,01	8.482,25	1.862,33	3.119,10
CON.DE	6.785,01	3.981,95	4.826,42	3.214,99	9.471,72	4.586,51	7.170,49	-528,28	2.344,07
DAI.DE	8.932,15	4.467,33	6.216,41	-1.067,85	9.106,97	4.160,38	6.697,23	-893,03	480,82
DB1.DE	20.847,38	14.574,18	16.703,23	10.847,38	16.962,52	10.174,60	13.591,40	6.962,52	-3111,83
DBK.DE	9.542,53	3.096,58	4.663,74	-457,47	5.622,59	2.645,70	3.892,91	-4.377,41	-770,83
DPW.DE	10.595,00	7.781,89	8.607,79	595,00	11.284,49	5.145,30	8.574,62	1.284,49	-33,17
DTE.DE	11.694,17	5.796,68	9.093,95	1.694,17	11.026,45	7.844,71	9.298,95	1.026,45	205,00
EOAN.DE	14.490,76	9.733,88	12.650,07	4.490,76	12.470,04	9.910,51	11.143,65	2.470,04	-1.506,42
FME.DE	11.869,51	6.910,99	9.079,01	1.869,51	14.035,77	8.654,79	10.986,33	4.035,77	1.907,32
FRE.DE	10.330,59	5.929,14	7.364,41	330,59	12.579,45	8.647,24	11.322,85	2.579,45	3.958,44
HEI.DE	10.672,38	4.748,70	6.403,63	672,38	9.446,03	4.542,30	6.193,55	-553,97	-210,08
HEN3.DE	8.899,58	6.360,35	7.018,19	-1.100,42	10.166,29	6.398,33	9.023,49	166,29	2.005,30
IFX.DE	10.263,59	7.278,52	9.089,54	263,59	11.884,12	6.693,77	8.969,47	1.884,12	-120,07
LHA.DE	14.300,22	6.242,53	8.003,62	4.300,22	12.858,99	5.223,11	7.807,86	2.858,99	-195,76
LIN.DE	11.794,11	7.444,30	10.614,41	1.794,11	11.539,76	8.537,72	9.900,82	1.539,76	-713,59
MRK.DE	13.024,75	7.009,77	10.173,94	3.024,75	10.859,94	8.409,54	9.761,69	859,94	-412,25
MTX.F	13.254,14	8.330,39	10.659,51	3.254,14	13.753,86	8.422,72	11.191,40	3.753,86	1.012,71
MUV2.DE	10.743,51	9.835,41	10.314,48	743,51	10.560,48	8.508,62	9.623,23	560,48	-691,25
RWE.DE	21.311,35	13.306,65	17.427,40	11.311,35	26.878,27	10.000,00	17.151,77	16.878,27	-275,63
SAP.DE	13.041,15	9.215,15	10.341,75	3.041,15	11.533,60	8.946,38	10.366,35	1.533,60	24,60
SIE.DE	9.112,07	5.838,69	7.343,57	-887,93	10.244,38	4.954,37	7.610,84	244,38	267,27
VOW3.DE	12.338,66	6.636,57	9.124,14	2.338,66	11.540,49	4.160,31	7.712,78	1.540,49	-1.411,36

Opombe: »max« pomeni maksimum, »min« minimum, »sred« srednjo vrednost (aritmetično sredino).  $\Delta$  označuje razliko med obema tipoma modelov (enotnim in posamičnim), kot sledi:  $\Delta = sred(enotni\_model) - sred(posamicni\_model)$ . Odebeljene vrednosti označujejo pozitivne vrednosti razlik, tj. kjer za dano delnico srednja vrednost enotnega modela presega srednjo vrednost posamičnega modela. Vse v denarnih enotah Eur.

Vir: D. Fister idr. (2021).

Razmik med maksimalno in minimalno vrednostjo je višji v primeru posamičnega modela, kar pomeni, da je ta manj robusten. To je tudi glavni razlog za enakovrednost obeh modelov,



navkljub temu da v najboljšem primeru lahko doseže precej višji končni donos. Posamični model nima vztrajnosti in je bolj dovzeten za stohastičnost in prekomerno učenje. Daljša zaporedja od  $T_s = 32$  bi delovanje lahko izboljšala, a le na račun zmanjšane odzivnosti modela. Enotni model je posamičnega premagal enajstkrat glede srednjih vrednosti, medtem ko je posamičen dosegel višjo srednjo vrednost v ostalih šestnajstih primerih. Za šestnajst izmed delnic je bilo ugotovljeno, da razmik med najnižjo in najvišjo vrednost ni bistven oz. je manjši od 1.000,00 Eur. V kolikor se je enotni model pokazal kot robustnejši (kar je ugodno), se je pokazal tudi kot bolj tog, kar pomeni, da v določenih primerih ni bil zmožen ustvariti donosa. S tem zaključujemo, da oba predlagana LSTM modela v najboljših primerih lahko konkurirata klasični pasivni (kupi-in-zadrži) ITS in nekoliko manj konkurirata v povprečju. Dejstvo seveda kliče k preučitvi in optimizaciji arhitekture in nadzornih parametrov.

### 3.4.4 Detajlna analiza trgovanja

Detajlna analiza objektivno vrednoti kakovost vsake posamezne ITS, za primer treh skupin finančnih indikatorjev:

1. končni profit in tveganost beta  $\beta$ ,
2. obseg trgovanja (št. izvedenih menjav) posamezne ITS,
3. Sharpeov kvocient, Jensenova alfa in Treynorjev kvocient.

Detajlno analizo izvedemo na vzorcu najboljših zagonov glede na končno vrednost portfelja (za predlagana modela enotne in posamične LSTM), za pasivno in klasične ITS pa je bil izveden en zagon. Prvi dve skupini finančnih indikatorjev sta bili izluščeni iz rezultatov zagona, medtem ko tretja s preračunavanjem. Rezultate detajlne analize tabelarično prikazuje tabela 7.

Tabela 7: Rezultati detajlne analize treh klasičnih ITS ter enotne in posamične LSTM ITS

		pasivna	RSI	MACD	enotni	posamični
<b>Vrednost</b>	$\delta$ (Eur)	261.136,06	244.964,33	118.463,91	266.268,29	<b>314.281,28</b>
<b>Donos</b>	$R_i$ (%)	-3,29	-9,27	-56,12	-1,38	<b>16,40</b>
<b>Beta</b>	$\beta$	<b>0,7746</b>	0,1812	0,5153	-0,0290	-0,0091
<b>Št. menjav</b>	max	1	11	<b>88</b>	30	36
	min	1	2	<b>34</b>	2	4
	sred	1,00	7,37	<b>68,04</b>	12,85	9,15
	std. odkl.	0,00	1,95	<b>9,88</b>	6,57	7,96
<b>Sharpe</b>	$S_a$	0,0765	-0,1336	-1,7529	0,0032	<b>0,2384</b>
<b>Jensen</b>	$\alpha_j$ (%)	1,38	-9,30	-53,69	-3,63	<b>14,32</b>
<b>Treynor</b>	$T$	-0,07	-0,60	-1,13	<b>1,16</b>	-15,77

Opombe: Odebeljeno so označene maksimalne vrednosti (po vrsticah). Najvišjo končno vrednost portfelja oz. donosa doseže posamična LSTM ITS. Pasivna ITS doseže najvišjo vrednost bete (relativne mere tveganja glede na indeks DAX30). Izpostavljamo negativne vrednosti bete enotne in posamične LSTM ITS. MACD ITS je najbolj frekventna ITS, tj. ITS z največ menjavami, medtem ko pasivna zabeleži le eno menjavo (na prvi trgovni dan). Povprečno enotna in pasivna LSTM ITS menjata 9- do 13-krat; pri tem enotna LSTM ITS nekoliko bolj pogosto. Posamična LSTM ITS doseže bistveno višje vrednosti Sharpeovega kvocienta in Jensenove alfe  $\alpha_j$ . Po drugi strani enotna LSTM ITS doseže najvišjo vrednost Treynorjevega kvocienta (edina doseže pozitivno vrednost).

Predpostavimo  $R_f = 2\%$ .

Prva skupina finančnih indikatorjev prikazuje premoč posamične LSTM ITS glede na ostale ITS. Donosnost slednje, ki znaša 16,40 %, je bistveno višja od donosnosti ostalih ITS, npr. od enotne LSTM ITS, ki je druga po vrsti in že beleži negativni donos (-1,38 %) glede na začetno vložena denarna sredstva. Tudi vse ostale ITS zaradi učinka nedavne pandemične krize v zadnjem obdobju dosežejo negativni donos oz. izgubo. Najvišjo izgubo, kot smo videli na sliki 11, doseže MACD ITS. Tveganost beta  $\beta$  je pri posamični LSTM ITS najnižja od vseh (celo negativna, podobno tudi za enotno LSTM ITS). Negativnost bete  $\beta$  je pogojena z želeno značilnostjo neodvisnosti predlaganih ITS, tj. kakršnokoli je že gibanje delniških tečajev, to gibanje ne vpliva na spremembe vrednosti portfelja. Obe predlagani ITS dobro držita vrednosti portfeljev, tako v medvedjih kakor tudi v bikovskih časih. Obenem posamična LSTM ITS poleg držanja vrednosti portfelja uspe zagotoviti tudi sprotno (blago) naraščanje vrednosti portfelja skozi čas. Opazimo, da teža obeh predlaganih LSTM ITS ni v izkoriščanju bikovskega trenda, temveč v omejevanju izgub.

Nadalje ugotovimo, da je beta  $\beta$  pasivne ITS glede na indeks DAX30 bistveno nižja od 1. To ni nepričakovano – indeks DAX30 namreč zajema 30 delnic, ki se s časom spreminjajo (mi smo jih statično zajeli 27). Dodatno je treba omeniti učinek transakcijskih stroškov pri trgovanju delnic in s tem povezane izgube (pasivna ITS ima le en transakcijski strošek). Te izgube hipno, sprotno in neodvisno vplivajo na vrednost portfelja (izrazito pri MACD ITS) in posledično na vrednost izračunane bete  $\beta$ . Teoretično se vrednost izračunane bete  $\beta$  z višanjem transakcijske aktivnosti niža, ker je gibanje tečaja bolj neodvisno od gibanja trga.

Kot smo že omenili, višja kot je vrednost Sharpeovega kvocienta, tem bolj je ITS donosna, primerna. Višje vrednosti Sharpeovega kvocienta pričajo o višji srednji vrednosti donosov posamezne ITS glede na trg (ob dani fiksni varianci donosov posamezne ITS glede na trg) oz. pričajo o nižji varianci donosov posamezne ITS glede na trg (ob dani fiksni srednji vrednosti donosov posamezne ITS). Ugotavljamo, da so pozitivne vrednosti Sharpeovih kvocientov dosegle naslednje ITS: pasivna ter enotna in posamična LSTM ITS; MACD in RSI ITS pa sta dosegli nekoliko negativen kvocient (za RSI) ter drastično negativen kvocient (za MACD).

Jensenovo alfo  $\alpha$  interpretiramo podobno kot Sharpeov kvocient: višje vrednosti alfe  $\alpha$  pomenijo bolj donosne (primerne, ugodne) ITS. Jensenova alfa  $\alpha$  sestoji iz dveh posameznih delov, donosa posamezne ITS  $R_i$  ter CAPM modela  $R_f + \beta_{iM} \cdot (R_m - R_f)$ , ki sta medsebojno odšteta. Prvi izmed njiju podaja dejansko donosnost, medtem ko slednji povprečno pričakovano donosnost. Iz rezultatov opazimo, da posamična LSTM ITS doseže za več kot 14 odstotnih točk višjo donosnost, kot se od nje pričakuje. Po drugi strani enotna LSTM ITS glede na izračunano beto  $\beta$  nekoliko zaostaja za pričakovanji. Najslabšo vrednost Jensenove alfe  $\alpha$  pričakovano doseže MACD ITS.

Rezultati Treynorjevega kvocienta zaradi negativnih bet  $\beta$  določenih ITS niso popolnoma relevantni. Sodeč po rezultatih sklepamo, da je enotna LSTM ITS najprimernejša od vseh, a moramo upoštevati dejstvo, da sta negativna tako števec kot imenovalec, kar zmotno nakazuje na pretirano uspešnost enotne LSTM ITS oz. zmotno nakazuje na izrazito neučinkovitost posamične LSTM ITS. S korekcijo negativnih bet  $\beta$  bi lahko trdili, da je slika podobna kot pri Jensenovi alfi  $\alpha$ : prevladuje posamična LSTM ITS, medtem ko je enotna LSTM

ITS nekoliko pod pričakovanji. Vztrajamo, da Treynorjeva analiza ni popolnoma merodajna v našem primeru in da je ne smemo interpretirati objektivno kot preostala dva indikatorja.

### 3.5 Diskusija

Razloga za umestitev LSTM kot osrednje metode ITS sta dva: (1) LSTM je prilagojena za razširjanje zaporednih podatkov (kar finančni podatki so), (2) LSTM je sposobna pomniti ugotovljene vzorce dosti dlje časa v primerjavi s konkurentkami. Sam vidim LSTM kot dober približek (ne)zavednih asociacij. Namreč, določen dogodek (ali dogajanje) na borzi lahko LSTM (trajno) ostane v spominu, kar pomeni, da če se prihodnjič ta dogodek ponovi, bo LSTM sposobna predvideti izid. Več ko bo takih dogodkov, uspešnejše bo predvidevanje. Uspešnejše kot bo predvidevanje, tem bolj smiselne/upravičene bodo akcije. Tem bolj smiselne bodo akcije, tem višji bo donos.

Zgornje zapisano zelo dobro drži v primerih modeliranja statičnega oz. nespreminjajočega se pojava. Ampak vemo, da so finančni trgi eni najmanj statičnih pojavov in da se spreminjajo dnevno, velikokrat nesistematično. Ključnega pomena zato je, da se s spreminjanjem pojava spreminja tudi model (kar upoštevamo pri praktični aplikaciji). In kot nam rezultati na dolgi rok predlagajo, skupni vzorci dejansko obstajajo in jih je moč zaznati ter beležiti skozi čas. In ne samo zaznati ter beležiti, temveč se tudi ravnati po njih.

Portfelja obeh tehnik LSTM sta bolj kot ne nekorelirana od delniškega indeksa. Ničelne (celo negativne) vrednosti bet spominjajo na identičnost netvegane obrestne mere z donosnostjo obeh tehnik, sinhrono se pojavlja tudi vprašanje kompromisa dvojice tveganje-donosnost. Ugotavljamo, da je mogoče s premetenim trgovanjem doseči praktično nično tveganje portfelja, a hkrati pozitivno donosnost. Kljub temu moramo opozoriti, da gre pri tem za najboljšo možno situacijo in da bo v povprečju donosnost krepko nižja. Naš razvoj bi zato moral biti vsaj deloma usmerjen tudi v ugotavljanje najboljšega možnega modela izmed množice vseh modelov, ki bo v največji meri zadovoljeval pričakovanja uporabnikov.

Na podlagi vzorca pridobljenih podatkov in opravljenih eksperimentalnih preizkusov ugotavljamo, da vrednosti končnih denarnih sredstev obeh izvedb globoke LSTM (tj. enotne in posamične), prekašata vrednosti končnih denarnih sredstev klasičnih trgovalnih strategij. Na podlagi statističnega vzorca zato sklepamo, da hipoteze H1 ne moremo zavrni.

Ugotovitev o ne-zavrnitvi hipoteze H1 je ugodna tako z vidika hipoteze H1 kakor tudi osrednje teze doktorske naloge. Praktično to pomeni, da ne samo, da je globoko LSTM kot eno izmed metod AI moč uporabiti za ITS, temveč tudi pomeni, da bo končni rezultat trgovanja uspešnejši kot pri klasičnih ITS. Vprašanje zakaj je temu tako se postavlja samo zase, vidimo tri konkretne predloge:

1. globoka LSTM v primerjavi s pasivno ITS (ki je najuspešnejša med klasičnimi), trguje aktivno, kar pomeni, da je sposobna posredovati v vsakem opazovanem časovnem koraku, posledično pa ima na razpolago veliko več možnosti za zasedanje kratkoročnih pozicij;
2. globoka LSTM v primerjavi s klasičnimi ITS opazuje veliko širši nabor vhodnih spremenljivk, npr. pasivna ITS sploh ne opazuje nobenih vhodnih spremenljivk, RSI ter

MACD pa vsaka po eno (po drugi strani globoka LSTM opazuje 43 vhodnih spremenljivk, posledično ima veliko širši pregled nad dogajanjem);

3. globoka LSTM v primerjavi s klasičnimi ITS je učljiva, kar pomeni, da se lahko nauči hitrega posredovanja in veliko hitreje omeji potencialne izgube (RSI in MACD pasivno čakata, da vrednost indikatorjev pade oz. naraste nad določeno fiksno izbrano mero, zanemarjata pa trend padanja oz. naraščanja).

Obstaja še dodatni, četrti, predlog, ki je težje opazen, nanaša se pa na sposobnost dolgoročnega pomnjenja zgodovine globoke LSTM. Če po Murphy (1999) povzamemo, da se zgodovina, s tem pa tudi trgovalni vzorci, na finančnih trgih ponavljajo, in da globoka LSTM te vzorce lahko prepozna ter si jih zapomni, potem lahko izpeljemo tudi, da si lahko globoka LSTM zapomni tudi najustreznejšo obliko posredovanja za dano gibanje vhodnih spremenljivk, s tem pa najustreznejše možno posreduje na finančnem trgu. Te sposobnosti klasične ITS nimajo.

## 4 EKSPERIMENTIRANJE Z IMPULZNO NEVRONSKO MREŽO

Četrto poglavje je namenjeno eksperimentom s SNN in posledično preverjanju veljavnosti hipoteze H2. Bralcu je sprva predstavljeno ozadje in kratka zgodovina razvoja SNN. Eksperimentiranja s SNN so izvedena kot odgovor na čedalje bolj prisoten trend izkoriščanja ANN druge generacije kot pojmovanja globokega biološkega učenja (česar eno z drugim nima dosti skupnega). Preizkusi s SNN so izrazito eksperimentalne narave, od tod nižja kakovost rezultatov. Poglavje sestoji iz petih podpoglavij, sprva je predstavljen uvod in osnovne zakonitosti SNN. Namen prvega podpoglavja je bralcu predstaviti idejno zasnovo SNN, učne algoritme, ki so bili do zdaj implementirani in postopek izkoriščanja SNN za doktorsko nalogo. Drugo podpoglavje podrobneje opisuje postopek izdelave RTC-SNN elektronskega vezja in pripravo zbirke podatkov. Bralec se lahko seznaní tudi s podrobnim načrtom elektronskega vezja. Zaradi nezmožnosti implementacije RTC-SNN za potrebe ATS (zaradi ogromnega števila nevronov) so eksperimenti RTC-SNN omejeni na poenostavljeno zbirko podatkov IRIS. Sledi opis eksperimenta preizkusa koncepta (učenja) s postopkom modificiranega STDP algoritma, krajše RTC-SNN+m. STDP, opredeljena sta tudi učni algoritem in psevdokod. Po izpeljanem učenju je izvedeno tudi testiranje (napovedovanje), čigar rezultati so predstavljeni tabelarično. Po vzoru fizičnega vezja so v programskem okolju MATLAB implementirane in-silico simulacije (tretje podpoglavje). Namen slednjih je posnemati delovanje RTC-SNN z matematičnim modelom za namene enostavnejšega preizkušanja nadzornih parametrov in optimizacije ter poljubnega širjenja števila nevronov in skritih plasti, medtem ko je arhitektura RTC-SNN vezja po drugi strani fiksna oz. veliko težje prilagodljiva. V sklopu tega podpoglavja je predstavljena tudi časovna analiza kompleksnosti izvajanja med namensko strojno opremo (FPGA) ter delovnim in strežniškim računalnikom. Analizo časovne kompleksnosti za namensko strojno opremo vključimo kot zanimivost; FPGA namreč slovi kot eden izmed najhitrejših orodij za izvajanje kompleksnih diskretnih operacij (kar SNN vsekakor je). Četrto podpoglavje zajema preizkuse SNN z algoritmom DE. Namen podpoglavja je primerjati rezultate preizkusov SNN+m. STDP z alternativnim učnim algoritmom (za katerega smo dokaj prepričani, da bo na primeru vzorca našel optimalno rešitev). Znova so sprva izvedeni preizkusi na primeru poenostavljene zbirke podatkov IRIS, sprva in-silico simulacije, nato še preizkusi z RTC. Končno je izveden preizkus SNN+DE za ATS. Podpoglavje se zaključí s polemikami za v bodoče. Zadnje podpoglavje je znova diskusija, ta orisuje prednosti SNN, še posebej vezja RTC s svetlobnim prenosom signalov in analogno tehniko. Dodatno so izvedeni statistični testi med vsemi metodami AI, ki so bile v doktorski disertaciji preizkušene, za ugotavljanje statistično značilnih razlik med njimi.

### 4.1 Uvod

SNN so najnovejše predstavnice ANN tretje generacije, ki v največji meri do zdaj zasledujejo fenomen dejanskih biološko možnih (angl. biologically plausible) možganov (Hazan et al., 2018). Raziskovalci napovedujejo, da bodo SNN sčasoma izrinile/zamenjale tradicionalne metode ML, katerim je podana le osnovna logika bioloških možganov, širše ozadje pa je dograjeno matematično/eksperimentalno. Ideja SNN mrež temelji na prenašanju informacij s pomočjo nevronskega impulza od nevrone preko dendritov (apičnih in bazalnih) do ostalih povezanih nevronov; teh je tipično »priklapljenih« 10 tisoč. SNN so podobne tradicionalnim vnaprej usmerjenim mrežam, oboje imajo namreč podobno strukturo, a je izvajanje razširjanja

za slednje veliko bolj kompleksno. Zaradi nedavnih začetkov so zaenkrat v preizkusni/eksperimentalni fazi, še posebej je trenutno v polnem zamahu razvijanje postopka učenja. SNN so predstavnice ANN, ki jih je moč učiti tako nenadzorovano kot nadzorovano, pri čemer so Hebbovo učenje, STDP in različne izvedenke BPG-ja le nekatere izmed učnih postopkov.

Izhikevich (2003, 2007) je pionir na področju modeliranja SNN nevronov, področja, tesno povezanega z nevrološkimi procesi. Sam pravi, da gre pri modeliranju za dve vprašanji: kako nevroni tvorijo impulze in kje je prag tvorjenja. Izhikevich na prvo odgovarja, da se nevroni sami od sebe ne prožijo, temveč se dajo prožiti (angl. neurons don't fire, they get fired), kar implicitno pomeni, da je proženje nevronov samo-gnan postopek, medtem ko za drugo ni enostavnega uniformnega odgovora. Nevroni se prožijo, ker so vzdražljivi (vzbujani, angl. excitable), njihova ravnovesja pa so bolj ali manj blizu prehodov (angl. bifurcations). Bližje kot je nevronovo ravnovesje prehodu, lažje (z manj spodbujanja) se bo da ta nevron prožil in obratno. Obstaja več tipov nevronov, katerih naloge so odvisne od funkcije, ki jo v živčevju opravljajo. Nevroni so sestavljeni iz jedra (angl. nucleus), specializiranih organelov in membranske ovojnice, ki jih po eni strani ščiti pred zunanostjo, po drugi pa omogoča interakcijo z zunanjim okoljem. V splošnem velja, da je vsak nevron preko dendriškega drevesja in aksonov povezan z več tisoč ostalimi nevroni; te povezave med nevroni v dendriškem drevesju imenujemo sinapse.

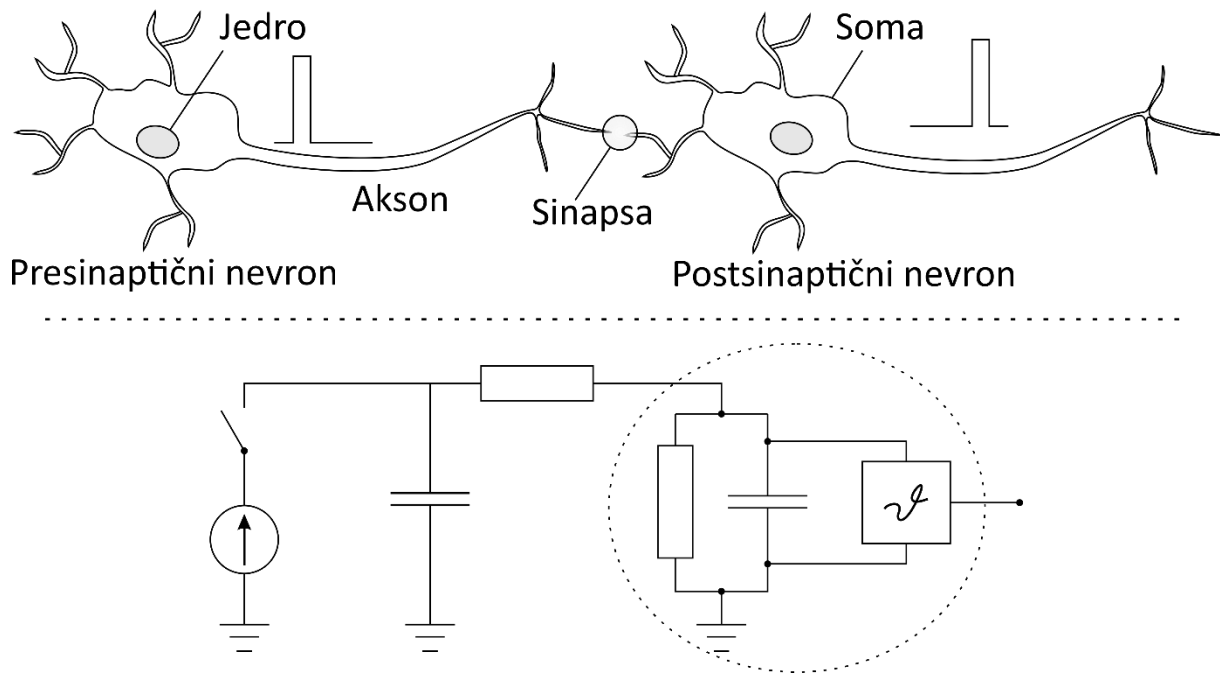
Pri sklicevanju na nevrone dejansko mislimo na 1) membranske potenciale nevronov (v nevronskega jedru), 2) njihove vhode, t. i. presinaptične akcijske potenciale, ki se fizično nahajajo pred nevroni in 3) izhode, t. i. postsinaptične akcijske potenciale, ki se nahajajo za nevroni. Membranski potencial nevrone se giblje med mirovnim potencialom (angl. resting potential) oz. bolje rečeno repolarizacijskim potencialom in potencialom podpraga (angl. subthreshold potential). Presinaptična aktivnost povzroči zvišanje (notranjega) membranskega potenciala, neaktivnost po drugi strani znižanje (oz. mirovanje). V kolikor se zaradi dovolj velike presinaptične aktivnosti membranski potencial zviša do potenciala praga (angl. threshold voltage  $\zeta$ ), nastopi kratkotrajni depolarizacijski impulz, ki povzroči postsinaptični akcijski potencial nevrone in takojšnjo repolarizacijo s kasnejšo refraktorsko periodo mirovanja pod repolarizacijskim potencialom. Z drugimi besedami pravimo, da je nevronska aktivnost kontinuiran proces depolarizacije iz negativnega potenciala do prelomne točke, kjer nevron odda impulz postsinapsi (angl. all-or-none spike), ponovne hiperpolarizacije in naknadne refraktorske periode (periode okrevanja), tj. periode, tekom katere je akcijski potencial pod mirovnim potencialom.

V nevronskega drevesju se tovrstni impulzi prenašajo s pomočjo nevroprenašalcev (s tujko neurotransmitterjev), ki po eni strani stimulirajo (ekscitirajo) nevronska aktivnost ali jo po drugi strani kot bilanca zavirajo (inhibirajo). Ozadje je znova popolnoma biološko in ga pobliže ne predstavljamo v tem delu.

V preteklosti so potekala številna eksperimentiranja in preizkušanja in-vitro na bioloških možganih podgan. Raziskave so bile velikokrat usmerjene v raziskovanje potenciala praga in najmanjšega električnega toka, ki povzroča kontinuirano aktivnost nevrone, s tujko rheobaza (angl. rheobase). Posledično so se tvorile raznorazne teorije delovanja posameznih nevronov, pojavili pa so se tudi elektronski modeli, ki v boljši ali manjši meri ponazarjajo/simulirajo biološke možgane. Eden izmed njih je zagotovo Hodgkin-Huxley model, poimenovan po

Hodgkin in Huxleyu iz leta 1952 (Hodgkin & Huxley, 1952). Mi smo se v tej raziskavi ukvarjali s poenostavljenim modelom nevrona, poimenovanim »puščajoči integriraj-in-sproži«, angl. leaky integrate-and-fire (Izhikevich, 2007). Slika 12 prikazuje model puščajočega integriraj-in-sproži (LIF) nevrona.

Slika 12: Primer presinaptičnega in postsinaptičnega nevrona, ki ju povezuje sinapsa (zgoraj) in pripadajoč elektronski model (spodaj)



Opombe: S sivo barvo sta označeni jedri nevrona, širše je prikazana nevrnska »soma«. Presinaptični nevron generira impulz, ki ga preko aksona pošlje do sinapse. Impulz se v postsinaptičnem nevronu integrira in v kolikor doseže prag, ta odda izhodni impulz, ki potuje do naslednjega/-jih nevrona/-ov. Impulz je v elektronskem modelu ponazorjen s tokovnim virov in pripadajočim stikalom. Sinapsa je predstavljena kot kombinacija vzporedno vezanega kondenzatorja in zaporedno vezanega upora. Tudi nevrnska soma, obkrožena s črtastim krogom, je predstavljena kot kombinacija upora in kondenzatorja. Dodan je komparator, tj. element, ki primerja akcijski potencial kondenzatorja (ali upora), in če ta preseže določeno vrednost – prag (na sliki označen z grško črko ζ), nevron tvori izhodni impulz (akcijski potencial). Poudariti želimo, da je celotno vezje z namenom, da v čim večji meri sledi biološkimi možganom, analogno.

#### 4.1.1 Modeliranje LIF nevrona

Model LIF nevrona lahko sestavimo s pomočjo elektronskih komponent, lahko pa ga modeliramo v obliki matematične enačbe, primerne za in-silico simulacije. Slednje so velike bolj prilagodljive in nudijo preglednejše sledenje signalom, a same po sebi ne upoštevajo morebitnih motenj in odstopanj, kar se v praksi stalno dogaja (posledično se kompromis med obema zdi najustreznejše dejanje). Namen tega podpoglavja je predstaviti matematični model LIF nevrona (in pripadajočo literaturo), ki ga lahko uporabimo za in-silico simulacije, slednjega zapišemo po Izhikevichu (2007):

$$C \cdot \dot{V} = I - g_{leak} \cdot (V - E_{leak}),$$

kjer je  $C$  kapacitivnost jedra,  $\dot{V}$  pa odvod membranskega potenciala (gre torej za dinamično, diferencialno enačbo).  $I$  predstavlja električni tok skozi sinapso (tega krmilimo z vrednostjo upornosti sinapse),  $g_{leak}$  pa prevodnost some (angl. conductance, tj. inverz upornosti).  $V$  predstavlja membranski potencial,  $E_{leak}$  pa začetni potencial, ki predstavlja mirovanje (v kolikor nevron ni vzbujen, potem je njegov akcijski potencial enak začetnemu potencialu). Začetni oz. mirovni potencial je navadno negativen, kar pomeni, da je nevron na dolgi rok (med operiranjem pod pragom) hiperpolariziran, tj. membranski potencial je negativen. Izpeljemo dva scenarija delovanja vezja:

1. Presinaptični impulz je prisoten, skozi sinapso steče tok, ki »napolni« kondenzator oz. povzroči pozitivno spremembo membranske napetosti (predpostavimo  $I > g_{leak} \cdot (V - E_{leak})$ , kar glede na majhnost  $g_{leak}$  ne bi smel biti problem). Večja kot bo kapacitivnost, manjši bo doprinos k membranski napetosti. Večja kot bo upornost sinapse, manjši bo tok, posledično bo manjši tudi doprinos k membranski napetosti. Upornost sinapse lahko poljubno spreminjamo in zato predstavlja utež SNN.
2. Presinaptični impulz ni prisoten, zato na nevronu pride do notranjega (ohmskega) »puščanja«. Magnituda tega puščanja je odvisna od razlike membranskega in mirovnega potenciala, pomnoženega s prevodnostjo. Vidimo, da ta prispevek povzroči negativno spremembo membranskega potenciala, v kolikor je tok skozi sinapso nič (tok skozi sinapso je nič, vedno ko na sinapsi ni prisotnega presinaptičnega nevrone, zapisano formalno:  $-g_{leak} \cdot (V - E_{leak})$ , saj je  $I = 0$ ). Manjša kot bo notranja upornost nevrone, večje bo puščanje in hitreje se bo membranski potencial izpraznil (repolariziral).

Elektronsko modeliranje posameznih nevronov in skupnih plasti SNN mrež je bilo v preteklosti že ničkolikokrat raziskano. Številni avtorji (Babacan et al., 2016; Elias & Rogers, 1991; Kanazawa et al., 2003; Kolka et al., 2019; Linares-Barranco et al., 1991; Pershin & Di Ventra, 2010; Toumazou et al., 1998) so se ukvarjali večinoma z analogno tehniko, medtem ko so sestavljene nevrone plasti in mreže z dodanim učnim algoritmom kombinirali s CMOS in digitalno tehniko. Tudi mi smo prepričani, da se dodana vrednost izvajanja tovrstnih mrež skriva ravno v analognem delovanju (po vzoru bioloških možganov). Xin & Embrechts (2001) sta objavila eno izmed pionirskih del na področju nadzorovanega učenja SNN nevronekih mrež, kjer gre zaslediti matematično izpeljavo učnega algoritma vzvratnega razširjanja (angl. error back propagation algorithm). Primer STDP postopka učenja za področje klasifikacije slik (števki) z uporabo enostavnih LIF nevronov so prikazali lakymchuk idr. (2015). Ghosh-Dastidar & Adeli (2009) sta v svojem delu predlagala nov tip SNN nevronekih mreže, poimenovan Multi-Spiking Neural Network (MuSpiNN) in posledično tudi nov algoritem učenja Multi-SpikeProp. V okviru klasifikacijskih študij sta avtorja zapisala, da predlagana mreža in algoritem učenja statistično značilno izboljšata zmogljivosti običajne SNN nevronekih mreže z običajnim algoritmom učenja. Brody & Hopfield (2003) sta predlagala t. i. mednevroneko sinhronizacijo impulzov, pri čemer sta avtorja zapisala, da je tak postopek še posebej koristen v primeru, ko so nevroni podvrženi podobnemu tempu (ritmu) proženja impulzov. Teoretično zasnovo prepoznavne vonjav »mitralnih celic« sta avtorja podprla z eksperimentalnimi in-silico preizkušnji. Izkazalo se je, da je SNN nevroneka mreža po predlagani izboljšavi robustnejša in odporna na spremenljive koncentracije vonjav. Tudi Sarkar idr. (2015) so se ukvarjali s podobno tematiko – s prepoznavanjem vonja s pomočjo t. i. elektronskega nosu. Belatreche idr. (2007) so predlagali nadzorovano učenje s pomočjo evulucijske strategije, krajše ES (Rechenberg, 1973). Avtorji so prilagodili tudi sinapso – slednjo so poimenovali dinamična sinapsa (DS). Zaradi časovne



kompleksnosti izvajanja učnega algoritma so avtorji predlagali izvajanje na FPGA; podrobno so implementacijo bioloških nevronov na FPGA pokazali Pearson idr. (2007). Tudi Pavlidis idr. (2005) so predlagali nadzorovano učenje z algoritmom vzporedne DE, namesto nenadzorovanega Hebbovega učenja, pri čemer so avtorji uporabnost algoritma testirali na znanih klasifikacijskih problemih. Eksperimentiranja so pokazala, da je predlagana metoda učenja primerljiva klasični večnivojski perceptronski mreži, učeči se z običajnim gradientnim postopkom. Kasneje se je pojavila tudi t. i. razvijajoča se SNN nevrnska mreža (angl. evolving SNN). V delu Schliebs & Kasabov (2013) lahko najdemo celotni pregled področja razvijajočih se SNN nevrnskih mrež. Avtorja sta predstavila nevrnski model, kodiranje vhodnih podatkov ter pripadajoče učenje SNN. Nadalje sta predstavila posebne izvedenke SNN nevrnskih mrež, npr. integrirano izbiro značilk, optimizacijo nadzornih parametrov in ekstrakcijo pravil (angl. rule extraction). Opisala sta tudi prepoznavanje (identifikacijo) prostorsko-časovnih vzorcev. Končno sta navedla najrazličnejše aplikacije SNN nevrnskih mrež. Razvijajoče se SNN nevrnske mreže so aplikativno uporabili Dora idr. (2016) na več primerih klasifikacije. Wade idr. (2010) so predstavili učni postopek SNN nevrnskih mrež, posebej prilagojen klasifikacijskim problemom, poimenovan »Synaptic Weight Association Training, krajše SWAT«. Opravljena preizkušanja so pokazala statistično značilno izboljšanje klasifikacijskih rezultatov, tako na učnem kakor tudi testnem vzorcu. N. Kasabov & Capecchi (2015) sta objavila znanstveni prispevek s področja modeliranja, prepoznavanja in razumevanja elektroencefalografskih (EEG) časovno-prostorskih signalov. Kasabov, eden bolj prepoznavnih raziskovalcev SNN nevrnskih mrež, je med drugim eden izmed ustanoviteljev svetovno znanega orodja za modeliranje SNN nevrnskih mrež, poimenovanega NeuCube<sup>18</sup> (N. K. Kasabov, 2014). Da so SNN nevrnske mreže izredno priljubljene za prepoznavanje EEG časovno-prostorskih signalov (vzporedno tudi za prepoznavanje finančnih in borznih signalov), pričajo naslednji znanstveni prispevki: (Adeli & Ghosh-Dastidar, 2010; Doborjeh et al., 2018; Luo et al., 2020; Nuntalid et al., 2011; Tan et al., 2021).

Z razvojem novih simulacijskih orodij se analogno modeliranje SNN med raziskovalci opušča, a po drugi strani narašča zanimanje za in-silico modeliranja in izvajanja SNN nevrnskih mrež. Hazan idr. (2018) so implementirali Python modul BindsNET, ki je prosto dostopen in omogoča hitro in učinkovito implementacijo SNN nevrnskih mrež. V delu najdemo primerjavo z ostalimi prosto dostopnimi ali plačljivimi orodji, kot npr. ANNarchy (Vitay et al., 2015), (Py)NEST (Eppler, 2008), CARLsim (Beyeler et al., 2015), NeMo (Fidjeland et al., 2009), PyNN (Davison, 2008), Nengo AI (Bekolay et al., 2014), SpiNNaker (Painkras et al., 2013), Brian 2 (Goodman & Brette, 2008), Brain2GeNN (Yavuz et al., 2016) in NeuCube (N. K. Kasabov, 2014). Večina orodij je zaradi zahtev po čim hitrejšem izvajanju zgrajena v programskem jeziku C++ z osrednjim Python vmesnikom.

Brette idr. (2007) so izvedli širšo analizo s področja simuliranja impulznih nevronov, simulacijskih orodij in strategij. Predstavili so razliko med sinhronskimi (v vsaki časovni enoti so posodobljeni vsi nevroni) in asinhronskimi (na podlagi dogodkov) algoritmi, zasnovo časovnega zamika in šuma v nevrnskih mrežah ter razlike sistemov s STDP in brez. Predstavili

---

<sup>18</sup> <https://www.neucube.io/>

so tudi grafične in tekstualne simulatorje SNN nevronske mreže, med drugim tudi NEURON<sup>19</sup>, GENESIS<sup>20</sup> in NEST<sup>21</sup>.

#### 4.1.2 Učni algoritmi SNN

Modeliranje SNN nevronov in mrež je le prvotni korak do njihove uporabnosti in samodejno ne prinaša učne sposobnosti. Slednje prinašajo učni algoritmi, ki po določenem pravilu prilagajajo učne uteži (v primeru SNN so to prilagodljive sinapse oz. njihove upornosti). V splošnem obstajajo tri oblike učenja, nadzorovano, nenadzorovano in spodbujevano, od tod tri družine učnih algoritmov. Naslednje podpoglavje zajema kratki pregled literature nadzorovanega in nenadzorovanega učenja s SNN, z željo približati bralcu motivacijo za našo odločitev o izbiri učnega algoritma za preizkuse SNN.

Eno izmed pomembnejših del na področju nenadzorovanega učenja SNN nevronske mreže sta zabeležila Diehl & Cook (2015). SNN nevronska mreža sta uporabila za razpoznavanje MNIST števok. Celotno zasnovo eksperimentiranja sta avtorja posvetila čim boljšemu posnetku bioloških možganov, zato sta predlagala zasnovo prevodnosti sinaps namesto električnega toka, STDP s časovno odvisno spremembo uteži, lateralno inhibicijo ter adaptivnim pragom. Čeprav sta avtorja uporabljala izključno nenadzorovano učenje, sta pri tem dosegla klasifikacijsko točnost 95 %, kar je več od celotne primerljive konkurence. V splošni praksi sta ne glede na doseženo točnost uporabna oba pristopa. Reid idr. (2013, 2014) so predstavili napovedovanje finančnih serij z uporabo posebej ustvarjene SNN nevronske mreže (polisinhrone SNN) in klasifikacijske zmožnosti primerjali z več nivojsko mrežo (angl. Multi-Layer Perceptron, krajše MLP) ter funkcijsko nevronska mrežo (angl. functional link neural network). Na osnovi različnih finančnih indikatorjev, še posebej letnega donosa, so avtorji ugotovili spodbudno delovanje za napovedovanje finančnih serij. Tudi Sun idr. (2016) so izkoristili zmožnosti SNN mreže, in sicer za napovedovanje finančnih serij, tokrat tečaja surovine (ogljika) na energetskem trgu. Študija je pokazala, da je kombiniranje SNN nevronske mreže z drugimi tehnikami lahko veliko bolj učinkovito kot samostojna SNN nevronska mreža; kljub temu pa je v obeh primerih napovedovanje tečajev surovin z uporabo SNN nevronske mreže možno. Kulkarni idr. (2013) so predlagali uporabo SNN nevronske mreže za kratkotrajno napovedovanje porabe električne energije. Eksperimentiranja s t. i. SNNSTLF modelom so pokazala enakovrednost predlaganega pristopa s SNNSTLF z ostalimi študijami iz literature. Hunsberger & Eliasmith (2015) sta objavila znanstveni prispevek na temo globokih SNN nevronske mreže z LIF nevroni na problemu klasifikacije slik (CIFAR-10 in MNIST). Končno sta Kasiński & Ponulak (2006) objavila pregled literature s področja SNN učnih algoritmov. Čeprav je bil članek objavljen že leta 2006, še vedno dobro odstira različne tehnike SNN učenja. Avtorja sta jih razdelila v sedem skupin:

1. gradientne metode;
2. statistične metode;
3. metode z linearno algebro;

---

<sup>19</sup> <https://www.neuron.yale.edu/neuron/>

<sup>20</sup> <http://www.genesis-sim.org/>

<sup>21</sup> <https://www.nest-simulator.org/>

4. evolucijske metode;
5. »Synfire« verige;
6. nenadzorovano Hebbovo učenje, odvisno od časovnosti impulzov;
7. »ReSuMe« metode oz. angl. Remote Supervision Method.

Pregled literature dobro prikazuje raznovrstnost in pluralnost SNN nevronske mreže, kakor tudi mnoga druga raziskovalna vprašanja in aplikacije, ki so v preteklosti pritegnile raziskovalce iz najrazličnejših področij. Dusheyko (2017) je praktično predstavil izvedbo klasifikatorja ročnih kretenj. Zaradi dosegljivosti programskega paketa in dobre dokumentiranosti izvedbe aplikacije smo to raziskovalno delo privzeli kot temeljno delo za naš razvoj. Ta je bil v grobem usmerjen v:

- izdelavo RTC-SNN elektronskega vezja, ki posnema 3-plastno SNN nevronske mreže, vezje za razširjanje je v celoti analogno, digitalno je izveden le učni postopek, povezave med sinapsami so izvedene s pomočjo optičnih kablov in optičnih pretvornikov;
- izdelavo in-silico SNN nevronske mreže, primerne za trgovanje na finančni borzi;
- preizkušanja;
- pretvorbe in-silico modela v format primeren za FPGA in časovno eksperimentiranje SNN nevronske mreže na FPGA.

Zaradi trenutno pomanjkljivega poznavanja SNN nevronske mreže na globalni ravni in povezav z dejanskimi možgani je delo izrazito eksperimentalne narave. Zaradi številnih nedorečenih pomanjkljivosti SNN nevronske mreže smo se osredotočili na preizkušanje delovanja koncepta in poročanje osnovnih zakonitosti, ki nastanejo pri delu s SNN nevronske mreže.

## 4.2 Izdelava RTC-SNN elektronskega vezja

Z besedno zvezo RTC-SNN poimenujemo elektronsko vezje, sestavljeno iz osnovnih analognih elektronskih komponent (upor, tranzistor, kondenzator), ki posnema biološko razširjanje impulznih signalov. Sinapse so v RTC-SNN nadomeščene z optičnimi vlakni, nastavljive memristorje pa posnemajo digitalni potenciometri. Pred sestavljanjem RTC-SNN elektronskega vezja smo izvedli simulacije v simulacijskem okolju PSpice, kjer smo predvideli tudi okvirne gabarite elektronskih komponent (uporov in kondenzatorjev). Predvideno elektronsko vezje, ki je prikazano na sliki 15, smo fizično izvedli na testne ploščice (angl. perfboard). Zaradi zahtevnega sestavljanja mreže smo se omejili na minimalno arhitekturo 3 – 2 – 2. Strukturo posameznih nevronov smo modelirali po vzoru priporočil Dusheyka (2017) kot LIF nevrone, a smo pri tem prilagodili časovne konstante za doseganje višje stopnje sledljivosti (originalni članek predlaga dolžino časovnega koraka 1 ms, kar je v praksi zaradi hitrega izvajanja težko slediti). Sinapse smo zaradi boljšega posnemanja sproščanja nevroprenašalcev v bioloških možganih modelirali kot optične povezave (s fotoni). Posledično je velik del RTC-SNN namenjen optičnim oddajnikom, sprejemnikom in optičnim vlaknom. Prevodnost sinaps smo modelirali z variabilnimi uporniki (digitalnimi potenciometri), katerih notranja upornost se spreminja v določenem razponu (odvisno od učnega postopka). Mikrokontroler Arduino Mega 2560 je skrbel za izvajanje učnega postopka in posodabljanje prevodnosti sinaps. Tabela 8 prikazuje lastnosti in nazive uporabljenih elektronskih komponent, fotografije 13 in 14 pa izdelano RTC-SNN vezje s komponentami.

Upornosti sinaps smo spreminjali med minimalno in maksimalno upornostjo digitalnih potenciometrov, za doseg dvojnje resolucije (namesto 256 možnih stanj smo jih dosegli 512) smo za prvi dve plasti SNN nevronske mreže uporabili polovične vrednosti upornosti potenciometrov z  $R = 50 \text{ k}\Omega$ , a zaporedno vezali po dva digitalna potenciometra. Zaradi težav z dobavljivostjo digitalnih potenciometrov smo na mesta digitalnih potenciometrov v zadnji (izhodni) plasti SNN postavili le enojne digitalne potenciometre z  $R = 100 \text{ k}\Omega$ . Vrednosti digitalnih potenciometrov smo nastavljali s pomočjo mikrokontrolerja Arduino Mega 2560 preko protokola I2C. Arduino je bil uporabljen tudi za sprejemanje impulzov posameznih nevronov in posledično izvedbo učenja. Deloval je tudi kot signalni generator trem vhodom v RTC-SNN mrežo (ti so označeni kot SG1, SG2 in SG3 na sliki 16), pri čemer so bile periode signalov natančno odmerjene z Arduinovimi časovniki in so sledile (prilagojenim) vrednostim značilk. Arduino je bil uporabljen tudi za poročanje rezultatov.

Tabela 8: Nabor uporabljenih elektronskih komponent

Proizvajalec in tip komponente	Vloga	Podrobnosti in funkcije
<b>Renesas Electronics ISL90842</b>	digitalni potenciometer	4-kanalni, $R = 50 \text{ k}\Omega$ , 8-bitni, 4 kom
<b>Analog Devices AD5263</b>	digitalni potenciometer	4-kanalni, $R = 50 \text{ k}\Omega$ , 8-bitni, 4 kom
<b>Renesas Electronics ISL23325</b>	digitalni potenciometer	2-kanalni, $R = 100 \text{ k}\Omega$ , 8-bitni, 2 kom
<b>Avago SFH756V</b>	optični LED oddajnik	valovna dolžina $\lambda_{peak} = 660 \text{ nm}$ , $\varphi = 2,2 \text{ mm}$
<b>Avago SFH250V</b>	optični sprejemnik	valovna dolžina $\lambda_{smax} = 850 \text{ nm}$ , $\varphi = 2,2 \text{ mm}$
<b>OMC FDPF 4001 EH</b>	optično vlakno (kabel)	polimer, simplex, $\varphi = 2,2 \text{ mm}$
<b>Texas Instruments NE555</b>	integrirano vezje, časovnik	konfiguriran kot monostabilni multivibrator
<b>LM258P in LM348N</b>	operacijski ojačevalnik	2-kanalni in 4-kanalni
<b>Arduino Mega 2560</b>	mikrokontroler	signalni generatorji, sprejemanje impulznih signalov nevronov, izvedba učnega postopka, posodabljanje digitalnih potenciometrov preko protokola I2C

Opombe: Nevroni so zasnovano statično, spreminjamo prevodnosti (upornosti) sinaps. Upornosti sinaps interpretiramo kot moč povezave med dvema nevronoma, tj. nižja kot je upornost, tem višja je prevodnost in tem bolj se akcijski potencial presinaptičnega nevrona prenese na dotični nevron (tako je tem večja tudi možnost za postsinaptični akcijski potencial dotičnega nevrona).

V splošnem je bil uporabljen naslednji nabor instrumentov in opreme:

- 2-kanalni signalni generator Rigol DG822 25 MHz,
- 3-kanalni napajalnik Tenma 72-13310 30V5AX2, 2,5V/3,3V/5V/3AX1,
- 4-kanalni osciloskop DS1074 Z Plus 70 MHz 1GSa/s,
- pomožna oprema: spajkalnik Erska i-CON Pico, multimeter Voltcraft VC150.

#### 4.2.1 Poenostavljena zbirka podatkov IRIS

Na RTC-SNN elektronskem vezju nismo preizkušali celotne finančne zbirke podatkov in avtomatiziranega mehanskega trgovanja, temveč smo vezje uporabili le za pridobivanje praktičnih izkušenj. Posledično smo namesto zelo kompleksne finančne zbirke podatkov uporabili manj kompleksno zbirko, ki je bila prilagojena za arhitekturo zgrajene RTC-SNN. Tako smo lahko v živo preizkusili pristop delovanja RTC-SNN, izsledke pa uporabili za izgradnjo in-silico simulacij. Te smo naknadno enostavno razširili tudi na kompleksnejšo finančno zbirko podatkov. Zasnova eksperimenta je potekala sledeče. Iz spletne strani UCI Machine Learning smo pridobili<sup>22</sup> testno zbirko podatkov IRIS dataset, ki obravnava tri različne razrede rož »iris« (setosa, virginica, versicolor). Za vsak primerek podaja zbirka podatkov štiri biološke (botanične) značilnosti (značilke) listov in cvetov. Celotna zbirka sestoji iz 150 primerkov podatkov, po 50 za vsak razred. Cilj zbirke podatkov je izdelati model z nadzorovanim učenjem, ki na podlagi podanih štirih vrednosti značilk pravilno napove kar največ razredov primerkov. Čeprav je prosto dostopna celotna zbirka podatkov (**Z**), smo to zaradi omejenih možnosti eksperimentiranja na RTC-SNN elektronskem vezju omejili na poenostavljeno zbirko podatkov **Z'**. Poenostavljena zbirka podatkov je zadržala le dva izmed treh razredov (ker je število izhodnih nevronov RTC-SNN elektronskega vezja enako 2), tj. razreda setosa in virginica. Izmed 150 primerkov smo se tako omejili na 100 primerkov (zbirka podatkov je simetrična), pri čemer smo sprva za učni vzorec dodatno selekcionirali le 40 primerkov, po 20 za vsak razred, medtem ko smo testni vzorec zgradili iz 10 primerkov (za vsak razred), pri čemer smo upoštevali, da se primerki učnega in testnega vzorca niso prekrivali. Tabela 9 prikazuje deskriptivno statistiko poenostavljene zbirke podatkov IRIS.

Tabela 9: Deskriptivna statistika poenostavljene zbirke podatkov IRIS **Z'**

		Razred »setosa«			Razred »virginica«		
Učni vzorec	Povp.	4,960	1,460	0,240	6,660	5,510	2,045
	Min.	4,400	1,200	0,100	5,800	4,800	1,400
	Maks.	5,500	1,900	0,600	7,900	6,400	2,500
	Stdev	0,333	0,160	0,119	0,555	0,415	0,317
	Skew	-0,095	0,822	1,625	0,770	0,367	-0,526
	Kurt	-0,666	1,599	3,478	0,171	-0,319	-0,640
Testni vzorec	Povp.	5,050	1,540	0,280	6,510	5,420	1,920
	Min.	4,600	1,000	0,200	5,600	4,800	1,500
	Maks.	5,400	1,900	0,500	7,700	6,700	2,300
	Stdev	0,222	0,237	0,114	0,623	0,627	0,225
	Skew	-0,720	-1,102	1,048	0,624	0,907	-0,164
	Kurt	1,103	2,868	-0,394	0,089	0,198	0,335

Opombe: povp=aritmetično povprečje, min=minimum, max=maksimum, stdev=standardni odklon, skew=koeficient asimetrije, kurt=koeficient sploščenosti.

Pred dejansko uporabo poenostavljene zbirke **Z'** smo vse elemente za potrebe neposredne uporabe v mreži SNN pomnožili s faktorjem  $\frac{65000}{7,9}$ ; števec 65,000 zaradi vrednosti 16-bitnega časovnika (angl. timer), imenovalc 7,9, ker je ta predstavljal največjo vrednost v





<sup>22</sup> <https://archive.ics.uci.edu/ml/datasets/Haberman%27s+Survival>

poenostavljeni zbirki  $Z'$ . Tako smo dosegli spremenljivo periodo signalnih generatorjev – večja kot je bila vrednost značilke poenostavljene zbirke  $Z'$ , krajša je bila časovna perioda signalov oz. večji je bil tempo signalov.






#### **4.2.2 Fotografije in načrt vezja**

Zaradi transparentnosti in sledljivosti vezja RTC-SNN so v prihodnjem podpoglavju priložene fotografije vezja, instrumentov ter uporabljenih orodij. Prav tako sta priložena detajlni načrt uporabljenega LIF nevrona ter celotne SNN mreže.

Slika 13: Fotografije izdelanega vezja RTC-SNN in pripadajočih komponent




Slika 14: Fotografije izdelane vezja RTC-SNN in pripadajočih komponent






Slika 15: Shematični prikaz »originalnih« sinapse in nevrona RTC-SNN



Opomba: Prikazane so vrednosti (gabariti) originalno zasnove sinapse in nevrona RTC-SNN. Te vrednosti se od eksperimenta do eksperimenta razlikujejo in so za vsak eksperiment zapisane po tabelah.

Slika 16: Shematični prikaz celotne mreže RTC-SNN



#### 4.2.3 Preizkus koncepta: učenje RTC-SNN s postopkom modificiranega STDP (RTC-SNN+m. STDP)

Preizkušanje učne sposobnosti SNN je potekalo na osnovi 40 primerkov zbirke podatkov IRIS. Preizkus učne sposobnosti smo izvedli s pomočjo RTC-SNN elektronskega vezja, katerega smo preko mikrokontrolerja Arduino povezali z računalnikom. Pri tem smo v realnem času preko serijske povezave UART spremljali napredek učenja. Za učenje in testiranje smo uporabili enake primerke, kar v sekciji ML zaradi poštenosti ni navada. Dodatno smo zato izvedli tudi preizkušanja na testnem vzorcu, ki so doprinesla k poštenosti ugotovitev. Pri RTC-SNN elektronskem vezju smo za razliko od simulacij po razširjanju vsakega izmed primerkov vezje najprej uravnovesili (izpraznili). To smo storili tako, da smo za določeno časovno periodo, enako  $sim\_len$ , razširjanje signalnih generatorjev zaustavili, da so se vse membranske napetosti ponastavile na vrednost mirovnega potenciala. Šele po preteku te periode smo pričeli z razširjanjem novega primerka.

Za potrebe preizkusa koncepta smo izvedli nekoliko prilagojen učni postopek Dusheyko (2017), ki je bil v večji meri posnet iz učnega postopka vzvratnega razširjanja na osnovi časovnosti oz. dogodkovnosti signalov (angl. Event-Driven Random Backpropagation, krajše eRBP) iz del (Lillicrap et al., 2016; Neftci et al., 2017; Samadi et al., 2017). eRBP sledi osnovni logiki nenadzorovanega Hebbovega STDP učnega postopka, ki veleva osnovno načelo da se nevroni, ki se prožijo skupaj, tudi povezujejo (angl. neurons that fire together wire together). Originalni učni postopek, kot ga predstavlja Dusheyko, smo nekoliko prilagodili. Določeni nevroni v mreži SNN niso nujno medsebojno povezani, kar Dusheyko praktično simulira z uporabo t. i. modularnega filtra (angl. modular filter). Ta bi sicer naj izboljšal kakovost učenja, a po drugi strani zmanjšal prostost SNN. Zaradi že tako majhnega števila nevronov smo uporabo modularnega filtra okrnili. Dodatno smo nekoliko prilagodili izračun vzvratne napake, čigar postopek smo formalizirali kot:

$$e^{(2x1)} = \frac{dej\_razred^{(2x1)}}{R_p} - \frac{stevilo\_impulzov^{(2x1)}}{t},$$

pri čemer  $e$  predstavlja vzvratno napako,  $R_p$  pa je refraktorska perioda, tj. glavna sprememba na pram Dusheyka (2017). Vzratna napaka se izračunava na izhodnih nevronih, v tem primeru na  $n = 2$  izhodnih nevronih. Enačba je zapisana vektorsko, v eksponentih so zapisane dimenzije vektorjev. **dej\_razred** predstavlja dejanski klasifikacijski razred (angl. class, možne vrednosti 0 ali 1) in je izluščen neposredno iz zbirke podatkov za dan razred, npr. *setosa* = [0 1] ali *virginica* = [1 0]. **stevilo\_impulzov** je število proženj izhodnih nevronov, skupaj  $stevilo\_impulzov^{(2x1)}/t$  pa tvori tempo impulzov (angl. spike rate, krajše *sr*). Večji kot je tempo impulzov  $i$ -tega izhodnega nevrona, večja je možnost, da SNN napove za dan primer, da pripada dotičnemu razredu. Primer:  $sr_1 = 0,1$  pomeni 10 izhodnih pulzov v prvih  $t = 100$  časovnih korakih za izhodni nevron št. 1,  $sr_2 = 0,2$  pomeni 20 izhodnih pulzov v prvih  $t = 100$  časovnih korakih za izhodni nevron št. 2. Večji tempo proženja sugerira, da je napovedan razred v tem preprostem primeru razred št. 2 oz. fizično gledano drugi nevron. Predstavljamo še praktični primer izračuna vzvratne napake (predpostavljamo, da primer pripada drugemu klasifikacijskemu razredu):

$$e^1 = \frac{0}{3} - \frac{10}{100} = 0 - 0,1 = -0,1,$$

$$e^2 = \frac{1}{3} - \frac{20}{100} = 0, \bar{3} - 0,2 = +0,1\bar{3}.$$

Iz predznakov izračuna vidimo, da izračun napake (1) po eni strani destimulira proženje neustreznih nevronov in da (2) po drugi strani spodbuja proženje ustreznih nevronov. Tako izračunana vzvratna napaka je nato uporabljena za izračun popravka izhodnega memristorja  $\Delta_{out}$ , kot sledi (znova zapisano vektorsko):

$$\Delta_{out}^{(2x2)} = \left[ \mathbf{e}^{(2x1)} \cdot \mathbf{hid}_2^{(2x1)} \quad \mathbf{e}^{(2x1)} \cdot \mathbf{hid}_2^{(2x1)} \right],$$

kjer  $\mathbf{hid}_2^{(2x1)}$  predstavlja stanje dveh vmesnih nevronov, tj. 0 = ni impulza, 1 = impulz prisoten. Velja omeniti, da je  $\Delta_{out}^{(2x2)}$  matrika, sestavljena iz dveh identičnih vrstičnih vektorjev množenja komponente s komponento  $\mathbf{e}^{(2x1)} \cdot \mathbf{hid}^{(2x1)}$ . Komponente  $\Delta_{out}^{(2x2)}$  so tako morebiti ničelne (če se dotičen nevron ni prožil oz. je izračunana napaka enaka nič) ali neničelne, če je prišlo do proženja nevrna in izračunana napaka ni enaka nič. Matrika  $\Delta_{out}^{(2x2)}$  je zatem nadalje pomnožena z učno konstanto  $\alpha$ , kot sledi:

$$\mathbf{M}_{out}^{(2x2)} = \mathbf{M}_{out}^{(2x2)} - \Delta_{out}^{(2x2)} \cdot \alpha,$$

kjer je  $\mathbf{M}_{out}^{(2x2)}$  matrika izhodnih vrednosti memristorjev (sinaps). Pred dejansko posodobitvijo na RTC-SNN vezju so vrednosti posameznih komponent  $\mathbf{M}_{out}^{(2x2)}$  končno omejene med spodnjo in zgornjo limito, tj.  $M_{min}, M_{max}$ . Podobno so izračunane tudi vrednosti vmesnih in vhodnih memristorjev, pri čemer se seveda dimenzije teh ustrezno spremenijo:

$$\Delta_{hid}^{(3x2)} = \mathbf{hid}_1^{(3x1)} \cdot \mathbf{e}'^{(1x2)},$$

$$\Delta_{inp}^{(3x3)} = \mathbf{gen}^{(3x1)} \cdot \mathbf{e}_i'^{(1x3)},$$

pri čemer je  $\mathbf{e}'^{(1x3)}$  modificirana vzvratna napaka, sestavljena, kot sledi:

$$\mathbf{e}'^{(1x3)} = [e^1 \quad 0 \quad e^2],$$

kjer srednji nevron predstavlja že omenjeni modularni filter (uteži te sinapse vseskozi ostajajo konstantne in so enake uvodnih nastavitvam vrednosti). Posodobitve sinaps so končno izračunane kot:

$$\mathbf{M}_{hid}^{(3x2)} = \mathbf{M}_{hid}^{(3x2)} - \Delta_{hid}^{(3x2)} \cdot \alpha,$$

$$\mathbf{M}_{inp}^{(3x3)} = \mathbf{M}_{inp}^{(3x3)} - \Delta_{inp}^{(3x3)} \cdot \alpha.$$

Velja omeniti, da gre pri množenju učne konstante znova za množenje elementa z elementom. Algoritem 3 prikazuje podroben psevdokod preizkusa koncepta SNN. Tabela 10 prikazuje nastavitve eksperimentalnih parametrov. Rezultate smo predstavili grafično, v obliki števila nepravilno klasificiranih primerkov (npr. 24 nepravilno klasificiranih primerkov od 40 predstavlja točnost 40 %). Znova poudarjamo, da smo RTC-SNN mrežo zgradili z namenom razumevanja delovanja in eksperimentiranja SNN mrež, ne pa tudi pričakanj o prodornih eksperimentalnih rezultatih.

**Algoritem 3: Preizkus učenja RTC-SNN+m. STDP**

```

UVODNO NASTAVI verigo vhodnih, vmesnih in izhodnih sinaps;
UVODNO NASTAVI vrednosti sinaps na naključne vrednosti med spodnjo in zgornjo limito;
UVODNO NASTAVI poenostavljeno zbirko podatkov  $Z'$ ;
UVODNO NASTAVI generatorje signala in pripadajoče časovnike;
DOLOČI učno konstanto  $\alpha$  in njen upad (angl. decay) skozi čas;
For št. epoh učenja: // št. offline epoh
    For št. primerkov učenja: // SNN učenje
        PONASTAVI kazalnike; // ponastavi
        RAZŠIRJAJ primerek;
        For št. sim_len:
            UČENJE SNN na učnem vzorcu; // razširjanje nazaj
            POSODOBI memristorje;
            HKRATI SNEMAJ rezultate klasifikacije;
        EndFor
        PREKINI razširjanje;
        For št. sim_len: // simetrija
            ČASOVNI ZAMIK (angl. delay); // umiritev memb. pot.
        EndFor
        IZPIŠI klasifikacijske rezultate;
    EndFor
    IZPIŠI vrednosti memristorjev;
EndFor

```

Opombe: uvodna nastavitve verige sinaps pomeni določitev: I2C naslova, št. kanalov, indeks prvega kanala in indeks drugega kanala (če je ta dejaven). »memb. pot.«=membranski potencial. Možni klasifikacijski rezultati: TP, TN, FP, FN.

Tabela 10: Nadzorni parametri RTC-SNN+m. STDP elektronskega vezja

Nastavitev	Oznaka	Vrednost
Arhitektura SNN		3 – 2 – 2
Učni algoritem		m. STDP
Limite dig. potenciometrov (sinaps)	$M_{min}, M_{max}$	7 k $\Omega$ , 100 k $\Omega$
Časovna konstanta	$dt$	0,01535 s
Simulacijska dolžina	$sim\_len$	200 · $dt$ (3,070 s)
Število epoh	$nEPOCH$	100
Začetne vrednosti uteži		$rand(35\text{ k}\Omega, 65\text{ k}\Omega)$
Potencial praga	$\zeta$	500 mV
Mirovni potencial	$u_{rest}$	0 mV
Kapacitivnost nevrona	$C$	1 $\mu$ F
Upornost nevrona	$R$	1 M $\Omega$
Refraktorska perioda	$R_p$	3
Učna konstanta (angl. learning rate)	$\varepsilon$	100
Upad učne konstante (angl. decay)		0,99
Napajalne napetosti		$\pm 12$ VDC, 5 VDC
Hitrost prenosa (angl. baud rate)		9600


Opombe: rand=naključne vrednosti (angl. random).

Kljub temu da je proces razširjanja SNN popolnoma analogen, pa je vzvratno razširjanje izvedeno s pomočjo digitalne tehnike. Gre torej za kombiniranje analogne in digitalne tehnike, pri čemer je najmanjša časovna perioda, v kateri lahko pričakujemo posodobitev digitalnega potenciometra (angl. update), enaka  $t = 0,01535$  s.

Ugotovitve preizkušanj učne sposobnosti SNN smo strnili v grafični obliki, prikazani na sliki 17. Slika prikazuje število nepravilno klasificiranih primerkov, ta variira med 22 in 40 od skupno 40. Po začetnem učenju je opazno skokovito izboljšanje klasifikacijskih rezultatov in naknadni upad (stagniranje). Grafična podoba nakazuje na dejstvo, da učni algoritem deluje, tj. s številom epoh vpliva na (spreminja) klasifikacijske rezultate, a so ti zelo odvisni od splošnega trenda učenja, npr. če učenje dobro zadane bistvo, se bodo rezultati hipno izboljšali, kar bo imelo ugoden vpliv tudi na nadaljnje rezultate. Obratno se lahko zgodi, da se bodo rezultati trajno poslabšali. Sodeč po sliki 17, je optimalno število epoh učenja (za dano kompleksnost skupno štirinajstih sinaps) med 30 in 55. Četudi so v tem razponu rezultati najbolj vzpodbudni, pa zaradi prenizke točnosti ne morejo biti uporabljeni v širši praksi. Rezultati namreč dosegajo skupno točnost pod 50 %, kar teoretično pomeni da se pri klasificiranju boljše odreže celo klasifikator, ki deluje na principu naključnosti. Vidimo več ozirov, zakaj prihaja do slabših rezultatov:

- Oba razreda sta enako frekventno zastopana (noben razred ni značilen), npr. oba izhodna nevrona signalizirata natanko pet signalov. V implementirani logiki to sproži klasifikacijski rezultat FP, ki skupno točnost poslabša. Problem enake zastopanosti leži v visoki podobnosti nastavitvev sinaps, kar pomeni, da odločajo malenkosti, te pa se mnogokrat ne odrazijo dovolj značilno. Rešitev tega ozira vidimo predvsem v podaljšanju števila korakov razširjanja (s tem ko podaljšamo periodo razširjanja, potencialno dosežemo boljše razpršitev) ali implementaciji logike, ki bi ugotovila, kateremu razredu dejansko signali pripadajo.
- Eden izmed izhodnih nevronov zaradi neustrezne nastavitve sinaps prevzame vodilno vlogo in signalizira večino impulzov. To je splošni problem mrež SNN, ki zahteva natančnejše eksperimentiranje in razlago, kliče pa po izboljšanju uteženosti učenja med posameznimi/-a nevroni/-oma.
- Enakovredno gibanje več ločenih memristanc (sinaps), potem ko slednje enkrat zadenejo zgornjo ali spodnjo limito. Pomeni, da ima več ločenih sinaps enake vrednosti memristanc, saj so učni signali vzvratnega razširjanja za določeno plast identični.
- Kompleksnost SNN (število sinaps) je za dan problem premajhna, dodatno tri izmed štirinajstih sinaps na račun modularnega filtra ne prilagajamo, zato SNN ne uspe zagotoviti strukturnih oz. smiselnih povezav med sinapsami in nevroni.
- Večina sinaps hitro po začetku razširjanju primerkov doseže stacionarno stanje, iz katerega se nato le minimalno premika. Ozir kliče na izboljšanje dinamičnosti algoritma učenja.
- V oči bode misel, da je poslabševanje rezultatov v drugi polovici znak, da učenje deluje, a ravno v nasprotno smer od zelenega.

Slika 17: Preizkus učne sposobnosti mreže RTC-SNN+m. STDP - število pravilno klasificiranih primerkov poenostavljene zbirke podatkov IRIS  $Z'$  v odvisnosti od števila epoh



#### 4.2.4 Preizkus koncepta: napovedovanje z RTC-SNN+m. STDP

Po izvedenih preizkušanjih učne sposobnosti SNN smo dodatno izvedli še preizkušanja na testnem vzorcu. Pri preizkušanjih na testnem vzorcu postopka vzvratnega razširjanja nismo znova ponavljali, temveč smo uporabili že znane vrednosti sinaps iz prejšnjih preizkušanj učne sposobnosti. Vrednosti sinaps smo zato vpisali ročno in jih skozi preizkušanja pustili zamrznjene. Uporabili smo vrednosti sinaps iz epohe št. 32. Rezultate smo predstavili tabelarično, v obliki kontingenčne tabele (tabela 11).

Med desetimi posamičnimi testnimi zagoni ( $N = 10$ ) smo ugotovili, da se število TP (in s tem tudi točnost) spreminja, četudi so vrednosti memristanc konstantne. Dejstvo si razlagamo z velikimi tolerancami digitalnih potenciometrov, to pa utegne pomeniti, da dejanske vrednosti memristanc niso konstantne skozi vse zagone. V tabeli 11 so prikazani rezultati povprečij iz desetih zagonov.

Tabela 11: Preizkus na testnem vzorcu - kontingenčna tabela s povprečnimi rezultati na osnovi desetih zagonov testnega vzorca

	Dejanski razred 1 ('setosa')	Dejanski razred 2 ('virginica')
Napovedan razred 1 ('setosa')	5,8 (TN)	10 (FN)
Napovedan razred 2 ('virginica')	4,2 (FP)	0 (TP)

Opombe: Vsota rezultatov znaša 20, točnost klasificiranja je 29 %. V oči bode nepravilnost klasificiranja dejanskega razreda 2. SNN več kot polovično dobro napove dejanski razred 1 (specifičnost znaša  $TN/N = 5,8/10 = 58\%$ ), a za dejanski razred 2 (občutljivost znaša  $TP/P = 0/10 = 0\%$ ). V prihodnje bi bilo treba algoritem prilagoditi tako, da bi ob enaki stopnji specifičnosti bistveno izboljšal rezultat občutljivosti.

Strinjamo se, da so rezultati klasificiranja za dejanski razred 1 (TN) vzpodbudni, medtem ko rezultati klasificiranja za dejanski razred 2 (TP) ne. Občutljivost modela bi bilo na vsak način treba izboljšati. Na podlagi eksperimentiranja z RTC-SNN elektronskim vezjem ugotavljamo sledeče:

- Visoka »konkurenčnost« učnega postopka in enakomerna porazdelitev razredov lahko povzročita nizko občutljivost modela. Potreben je element naključnosti, ki učinkovito zmanjša neustrezno konvergenco oz. mreži povrne učne sposobnosti.
- Vhodni signali se naj pojavljajo konstantno periodično, a naj bodo v začetku čim bolj razpršeni (angl. offset, da se preprečijo hkratni impulzi na vseh vhodnih sinapsah).
- Število sinaps (s tem pa tudi nevronov) naj bo karseda veliko. S tem se zagotovi prostost SNN, da lahko vzpostavi poljubne vzorce in povezave.
- V kolikor število nevronov iz predhodne plasti v naslednjo plast upada, gre za pričakovati tudi upad frekvenca impulzov (ta upad frekvenca lahko reguliramo z nižanjem napetosti praga, a lahko pri prekomerno nizko nastavljenem pragu povzročimo pristranskost SNN). Znova priporočamo čim večje število sinaps in nevronov, ki zagotovijo, da upad frekvenca ni bistven.
- Potrebno je zagotoviti čim večjo značilnost (različnost) posameznih nevronov tako, da se čim bolj zmanjša število enakovrednih proženj zunanjih nevronov. Število korakov naj bo čim večje, prav tako kompleksnost mreže. To bo ugodno vplivalo tudi na zmanjšanje upada frekvenca iz plasti v plast.
- Spodnje in zgornje limite morajo biti nastavljene dovolj nizko ali visoko, da se zagotovi prostost SNN.
- Preprečiti je treba slabo specifičnost ali občutljivost mreže – če mreža deluje, mora pravilno klasificirati tako TN, kakor tudi TP primerke (ne pa samo enega izmed njih). Dejstvo znova kliče na izboljšanje učnega algoritma. Tak problem se lahko pojavi tudi, če eden izmed nevronov prevzame vodilno vlogo in se posledično proži velikokrat več kot ostali.
- Odstopanje elektronskih komponent od toleranc mora biti čim manjše. Žal smo na tržišču lahko dobili le digitalne potenciometre s točnostjo  $\pm 20\%$  oz. celo  $\pm 30\%$ , kar lahko bistveno vpliva na klasifikacijske rezultate. Odsvetujemo tudi digitalne potenciometre različnih proizvajalcev (mi smo jih bili primorani uporabiti zaradi enotnega I2C vodila; problem nastane, ker imajo enaki digitalni potenciometri enakega proizvajalca identičen I2C naslov). Tovrstnim težavam se pri simulacijah in-silico elegantno izognemo.

### **4.3 In-silico simulacije upravljanja portfelja delnic s SNN mrežo s postopkom modificiranega STDP (simulacije in-silico SNN+m. STDP)**

Simulacije in-silico aktivnega borznega trgovanja s SNN smo izvedli po začetnih preizkušanjih z RTC-SNN elektronskim vezjem. Izvedli smo dvojce različnih preizkusov, (1) simulacije v programskem okolju MATLAB, katere smo zagnali na delovnem in strežniškem računalniku, ter (2) simulacije, ki smo jih implementirali in zagnali na FPGA. Oba preizkusa sta bila namenjena za preverjanje veljavnosti hipoteze H2 o umestitvi SNN kot ITS ter o zagonu SNN na FPGA.



#### 4.3.1 Simulacije in-silico v programskem okolju MATLAB (SNN+m. STDP)

In-silico simulacije smo implementirali v programskem okolju MATLAB in jih zagnali na delovnem ter strežniškem računalniku. Izvedene simulacije so sledile filozofiji že preizkušenega RTC-SNN vezja, za postopek učenja je bil znova uporabljen modificiran Dusheykov postopek. Namen simulacij in-silico je bil preveriti veljavnost prvega dela hipoteze H2, tj. umestitvi SNN kot ITS. Nadzorne parametre SNN prikazuje tabela 12, rezultate tabela 13.

Tabela 12: Nadzorni parametri simulacije in-silico SNN+m. STDP

Nastavitev	Oznaka	Vrednost
Arhitektura SNN		43 – 45 – 3
Učni algoritem		m. STDP
Limite dig. pot. (sinaps)	$M_{min}, M_{max}$	100 M $\Omega$ , 5 G $\Omega$
Časovna konstanta	$dt$	1 ms
Simulacijska dolžina	$sim\_len$	$200 \cdot dt$ (3,070 s)
Št. offline epoh	$N_{offline}$	100
Začetne vrednosti uteži		$rand(35 \text{ k}\Omega, 65 \text{ k}\Omega)$
Potencial praga	$\zeta$	variabilen: $1e^{-3}, 5e^{-3}, 1e^{-2}, 3,5e^{-2} \text{ V}$
Mirovni potencial	$u_{rest}$	-70 mV
Presinaptični potencial	$u_{presynaptic}$	30 mV
Kapacitivnost nevrona	$C$	35 pF
Puščanje (lekaža)	$L_f$	0,27
Refraktorska perioda	$R_p$	3
Offline (padajoča) učna konst.	$\epsilon$	variabilna: $1e^3, 5e^3, 10e^3$
Časovni horizont	$n$	1
Velikost učnega vzorca		1717
Velikost testnega vzorca		843
Transakcijski stroški		1 %
Začetna prosta denarna sredstva		10.000,00 Eur
Št. delnic v portfelju	$k$	27
Št. neodvisnih zagonov	$N$	10

Opombe: rand=naključne vrednosti (angl. random).

Simulacije in-silico smo zagnali na sledečih računalnikih:

- delovni računalnik HP 400 G4 MT z i5-7500 in 24 GB RAM,
- strežniški računalnik HP ProLiant DL360 G7 z 2x Xeon X5675 in 64 GB RAM.

Analiza časovne kompleksnosti je zajeta v naslednjem poglavju.

Tabela 13: Rezultati in-silico preizkusov

		$\epsilon$		
		$1e^3$	$5e^3$	$10e^3$
$\tilde{z}$	$1e^{-3}$	1,7612	0,8898	0,7366
	$5e^{-3}$	2,2719	1,2973	1,1265
	$1e^{-2}$	<b>2,7506</b>	2,6096	2,6069
	$3,5e^{-2}$	2,6152	2,7*	2,7*

Opombe: Vrednosti v tabeli so v enotah  $e^5$ . \*=zabeležena ni nobena tržna aktivnost; čeprav je rezultat na prvi pogled vzpodbuden, je takšen rezultat zaradi zadržanja začetnih prostih denarnih sredstev. Največja tržna kapitalizacija je odebeljena (pri  $prag = 1e^{-3}$  in  $\epsilon = 1e^3$ ). Smiselna bi bila dodatna eksperimentiranja z učno konstanto  $\epsilon < 1e^3$  in pogostejši raster med  $prag = 5e^{-3}$  in  $prag = 3,5e^{-2}$ .


Najvišji donos, ki ga je SNN dosegla, je znašal 1,9 % (končna tržna kapitalizacija enaka 275.060 Eur proti začetnim 270.000 Eur). Ostali eksperimenti so zabeležili izgubo; dva izmed njih nista pokazala trgovalnih vzorcev, prosta denarna sredstva so zato ostala nedotaknjena. Ugotovili smo, da sta obe variabilni spremenljivki, tj. nastavitve spremenljivke  $prag$  in učna konstanta  $\epsilon$ , ključnega pomena pri uspešnosti trgovanja SNN.

Rezultati in-silico simulacij so konsistentni:

- Z naraščanjem učne konstante  $\epsilon$  končna tržna kapitalizacija upada. To je razvidno v vseh primerih nastavitve  $prag$ , razen pri  $prag = 3,5e^{-2}$ , kjer zaradi neaktivnosti ITS ne pride do trgovanja.
- Naraščanje nastavitve  $prag$  povzroči naraščanje končne tržne kapitalizacije, a le do neke meje. Po tej meji je razvidno upadanje tržne kapitalizacije, kar je povsem smiselno. Potrebna bi bila dodatna preizkušanja, s pomočjo katerih bi to mejo lahko določili.

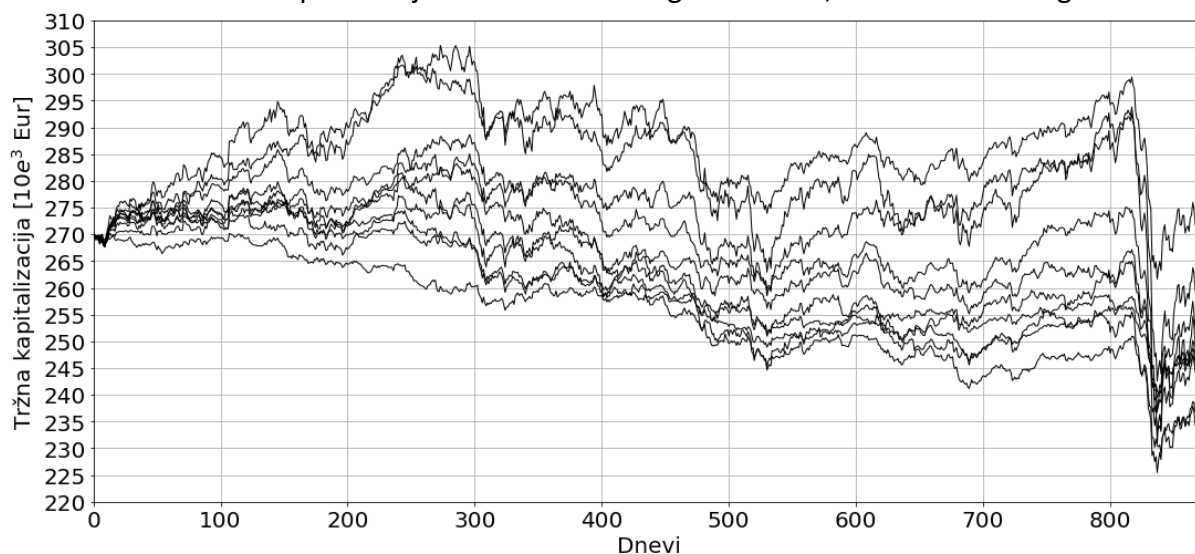
Rezultat trgovanja z največjo donosnostjo prikažemo tudi grafično (na sliki 18). Vidimo, da tržna kapitalizacija kmalu po začetku trgovanja bistveno narašča, nakar ji sledi močna korekcija tečajev navzdol. Po približno polovici trgovalne periode znova pride do trendnega naraščanja tržne kapitalizacije, kateri končno sledi močan upad zaradi pandemične krize. Kapitalizacija se v zadnjih tednih še nekoliko poveča in zagotovi pozitiven donos glede na vložena začetna prosta denarna sredstva. Rezultati SNN se bistveno razlikujejo (so slabši) od rezultatov LSTM, pri trgovanju s SNN namreč ne opazimo učinkovitega zmanjševanja izgub podobno kot pri LSTM.

Slika 18: Trgovanje, simulacije in-silico SNN+m. STDP



Konfiguracijo, ki se je v in-silico preizkusih pokazala kot najboljša ( $\epsilon = 1e^3$ ,  $prag = 1e^{-2}$ ), smo zaradi zagotavljanja ponovljivosti zagnali  $N = 10$  (poleg zgornjega še devetkrat). Vseh deset preizkusov je prikazanih na sliki 19.

Slika 19: Tržna kapitalizacija v odvisnosti od trgovalnih dni, 10 neodvisnih zagonov



Ugotavljamo, da je v vseh desetih primerih trgovanj SNN generirala trgovalne signale, saj se je tržna kapitalizacija spreminjala (pri večini primerov se je ta spreminjala že od samega začetka trgovanja). Opazimo dva oz. tri primere trgovanj ki se od ostalih ločijo po tem da dosežejo nekoliko višji končni trgovalni donos in en oz. dva primera trgovanj, ki se ločita po nižjem trgovalnem donosu. Ostali zagoni so blizu povprečja. Učinek pandemične krize vpliva na vse zagone trgovanj zelo podobno, saj se tržna kapitalizacija na ta račun pomembno zmanjša pri vseh trgovanjih. Minimalna končna tržna kapitalizacija vseh desetih zagonov znaša približno 236.310,00 Eur, medtem ko standardni odklon 11.333,80 Eur. Ugotovimo, da SNN ne uspe omejiti izgub v tolikšni meri, kot jih uspeja omejiti obe varianti LSTM mrež, posledično pa je uspeh trgovanja s SNN toliko manjši.

#### 4.3.2 Simulacije in-silico na FPGA in primerjava časovne kompleksnosti (FPGA-SNN+m. STDP)

Podpoglavje o simulacijah in-silico na FPGA je bilo namenjeno za preverjanje drugega dela hipoteze H2, tj. o umestitvi simulacij in-silico SNN+m. STDP na FPGA. Nameščanje programa in konfiguracija FPGA sta potekala s pomočjo orodja Xilinx Vivado Suite, uporabljena je bila kombinacija programskega jezika C in konfiguracijskega jezika Verilog. Uporabljen FPGA je bil tipa MicroZed Evaluation Kit (AES-Z7MB-7Z020-SOM-G/REV-G) z vgrajeno opremo Zynq-7000 in procesorjem ARM Cortex-A9. Na FPGA smo implementirali dvoje preizkusov (in-silico trgovanj):

1. Učenje in testiranje: za delnico ADS.DE je izvedeno kompletno učenje,  $sim\_len = 200$ ,  $N_{offline} = 100$ , po vsaki epohi učenja je izveden test.  $N_{instances} = 1748$ ,  $N_{instances\_test} = 874$ .
2. Testiranje: izvedeno je testiranje in sprotno (online) učenje,  $sim\_len = 1$ ,  $N_{instances\_test} = 874$ ,  $N_{online} = 10$ .

Implementacijo SNN smo na FPGA izvedli s celoštevilsko aritmetiko (to dejstvo moramo upoštevati pri primerjanju časovne kompleksnosti FPGA v primerjavi z delovnim in strežniškim računalnikom). Rezultatov in-silico trgovanj ne predstavljamo znova, pač pa se osredotočimo na ugotavljanje časovne zahtevnosti (tabela 14). Programska koda znotraj programskega okolja MATLAB je bila sprva zasnovana tako, da se je izvajala na enojnem CPU jedru brez večprocesorskega vzporednega računanja (tako smo omogočili zaganjanje velikega števila simulacij za celotni portfelj hkrati; pri kasnejših eksperimentiranjih smo programsko kodo modificirali tako, da se je izvajala po vseh možnih jedrih). Strežniški računalnik se je pokazal kot najpočasnejši izmed treh variant. Predvidevamo, da na račun nekoliko nižje delovne frekvence 3,07 GHz v primerjavi s frekvenco 3,4 GHz delovnega računalnika, medtem ko je FPGA značilno hitreje opravil z izračuni tako učenja in sprotnega testiranja, kakor tudi izključno testiranja.

Tabela 14: Časovna kompleksnost izvajanja učenja ter testiranja SNN+m. STDP

		FPGA	Delovni računalnik HP 400 G4 MT	Strežniški računalnik HP ProLiant
Učenje in testiranje	Povp.	00:00:0,435	0:29:36	00:42:53
	Min.	00:00:0,435	0:29:26	00:42:20
	Maks.	00:00:0,435	0:29:41	00:43:07
	Stdev	00:00:0,000	00:00:05	00:00:13
	Skew	-0,699	-1,357	-2,279
Testiranje	Povp.	00:00:0,148	81,960	116,290
	Min.	00:00:0,148	81,000	114,667
	Maks.	00:00:0,148	82,779	117,069
	Stdev	00:00:0,000	0,440	0,669
	Skew	-0,200	-0,511	-1,660

Opombe: Učenje in sprotno testiranje podana v formatu *hh:mm:ss*, validacija v s.  $N = 10$ . Stdev=standardni odklon, skew=koeficient asimetrije.

Povprečni čas izvajanja učenja in testiranja je na delovnem računalniku znašal nekoliko več kot 29 minut, medtem ko na strežniškem skoraj tri četrt ure. Povprečni čas testiranja je na FPGA skupaj z uvodno nastavitvijo in pošiljanjem zastavic med FPGA-jem in CPU-jem znašal slabe pol sekunde. Pohitritev izvajanja algoritma na FPGA je enormna. Raziskovalci navadno poročajo, npr. Fujimori & Watanabe, 2016; Zhou idr. (2015), da so FPGA več kot 1000-krat hitrejši od navadnih CPU-jev, tj. delovnih ali strežniških računalnikov. V našem primeru se izkaže, da je izvajanje algoritma na FPGA več kot 3000-krat hitrejše, sumimo, da na račun neoptimirane MATLAB/Simulink programske kode. Pohitritev je nekoliko manjša za testiranje, tam je FPGA hitrejši za okrog 500-krat od delovnega računalnika. Kar je pri FPGA-ju najbolj zanimivega – z naraščanjem kompleksnosti mreže časovna kompleksnost ne narašča (ker se celotna konfiguracija izvaja vzporedno). Kljub temu kompleksnosti ne moremo povečevati v nedogled, saj ima vsak FPGA število t. i. asociativnih polj (angl. LookUp Table, krajše LUT) omejeno.

Z eksperimentom časovne kompleksnosti smo v prvi vrsti pokazali, da je programsko kodo moč implementirati na FPGA vgrajeni sistem. Dodatno smo pokazali, da gre z izvajanjem programske kode na FPGA bistveno skrajšati časovno kompleksnost izvajanja (četudi je FPGA miniaturnih dimenzij v primerjavi z delovnim, kaj šele strežniškim računalnikom). Programska koda na FPGA kliče po nadaljnji optimizaciji kode in izbiri hitrejšega (prevajalniškega) programskega jezika, npr. C, s pomočjo katerih bi časovno kompleksnost lahko znova bistveno znižali (velja namreč omeniti, da implementirana programska koda ni bila optimirana za uporabljen FPGA).

#### **4.4 Nadgradnja učenja SNN z algoritmom DE (SNN+DE)**

Osnovni problem implementiranega vzratnega razširjanja v zgornjem poglavju je uporaba nenadzorovane učne metode za doseg nadzorovanega učenja. Glede na nekoliko nepričakovano slabe rezultate klasificiranja s SNN smo zasnovali optimizacijski učni algoritem na osnovi DE, ki je eden izmed vidnejših predstavnikov evolucijskih metod. Izvedli smo dodatna simulacijska preizkušanja in preizkušanja na RTC-SNN elektronskem vezju in pri tem ugotovili, da algoritem DE bistveno izboljša učne zmogljivosti mrež SNN, posledično pa lahko dosežemo bistveno izboljšano klasificiranje. S predlagano nadgradnjo smo izvedli dvoje preizkusov:

1. simulacije in-silico SNN+DE,
2. preizkus RTC-SNN+DE.

DE je populacijski, metahevristični optimizacijski algoritem, ki na množici genetskih vektorjev operira s tremi genetskimi operatorji: mutacijo, križanjem in selekcijo. Prva sta ga predstavila in implementirala Storn & Price (1997), pri čemer sta mutacijo določila s skaliranjem razlike dveh različnih genetskih vektorjev in prištevanjem izračunane razlike tretjemu (poskusnemu, angl. trial) vektorju. Tako pridobljen poskusni vektor je nato podvržen križanju, tj. postopku za neposredno spreminjanje genskega materiala, ki je še posebej uporabno v časih nizke genske raznolikosti (oz. ujetju v lokalnem optimumu). Križanje tipično ni izvedeno za vsak poskusni vektor, temveč le pri določenih izbranih. Višja kot je verjetnost križanja, več poskusnih rešitev bo podvrženih križanju, in obratno. Končno je izvedena tudi selekcija, ki izbere boljši (primernejši) vektor (sodeč po indikatorju ocenitvene funkcije) izmed tarčnega in poskusnega vektorja.

Simulacijska in-silico preizkušanja smo zaradi pravične primerjave prilagodili arhitekturi RTC-SNN elektronskega vezja, tj. arhitekturi 3 – 2 – 2. Pri tej arhitekturi je prisotnih 19 sinaps, kar ustreza  $nDIM = 19$ , ki jih algoritemsko predstavimo kot:

$$\mathbf{M}_i^{(t)} = \langle M_{i1}^{(t)}, M_{i2}^{(t)}, \dots, M_{inDIM}^{(t)} \rangle.$$

Število sinaps izračunamo po naslednjem postopku, ki upošteva dano arhitekturo SNN:

$$nSim^{(hid_1)} = 3 \cdot 3 = 9,$$

$$nSim^{(hid_2)} = 3 \cdot 2 = 6,$$

$$nSim^{(out)} = 2 \cdot 2 = 4,$$

pri čemer  $nSim^{(hid_1)}$ ,  $nSim^{(hid_2)}$ ,  $nSim^{(out)}$  označujejo število sinaps v prvi skriti plasti, število sinaps v drugi skriti plasti ter število sinaps v izhodni plasti. Zaradi neznane optimalne vrednosti kapacitivnosti  $C$  dodamo dodatno dimenzijo problema, ki ga tako razširimo na  $nDIM = 20$ . Reprerentacija posameznikov se tako ustrezno spremeni v:

$$\mathbf{x}_i^{(t)} = \langle M_{i1}^{(t)}, M_{i2}^{(t)}, \dots, M_{i19}^{(t)}, C_i^{(t)} \rangle.$$

Z razširitvijo predstavitve posameznikov za dodatno dimenzijo dosežemo enostavno vključitev kapacitivnosti  $C$  (ki bistveno vpliva na razširjanje impulzov skozi mrežo) v optimizacijski proces. Vektor posameznikov  $\mathbf{M}_i^{(t)}$  posledično preimenujemo v  $\mathbf{x}_i^{(t)}$ , ta je nato podvržen mutaciji, ki jo formalno zapišemo kot:

$$\mathbf{u}_i^{(t)} = \mathbf{x}_{r0}^{(t)} + F \cdot (\mathbf{x}_{r1}^{(t)} - \mathbf{x}_{r2}^{(t)}), \text{ za } i = 1, \dots, nPOP,$$

pri čemer  $F$  predstavlja skalirni faktor in je prvi izmed nadzornih parametrov algoritma DE,  $u_{i,j}^{(t)}$  pa je mutant oz. nov poskusni vektor.  $nPOP$  poimenujemo velikost populacije; večja kot je populacija, več poskusnih rešitev bo preizkušenih znotraj ene generacije, medtem ko so  $r0, r1, r2$  naključna, različna cela števila (indeksi), s katerimi naslavljammo vektorje. Mutant je v odvisnosti od naključne vrednosti  $CR$  podvržen križanju, kot sledi:

$$w_{i,j}^{(t)} = \begin{cases} u_{i,j}^{(t)}, & \text{če } rand_j(0,1) \leq CR \vee j = j_{rand}, \\ x_{i,j}^{(t)}, & \text{sicer,} \end{cases}$$

pri čemer  $w_{i,j}^{(t)}$  označuje posamezni element poskusnega vektorja,  $CR$  pa je drugi nadzorni parameter algoritma DE, tj. verjetnost križanja. Poskusni vektor končno primerjamo s tarčnim vektorjem, kot sledi:

$$\mathbf{x}_i^{(t+1)} = \begin{cases} \mathbf{w}_i^{(t)}, & \text{če } f(\mathbf{w}_i^{(t)}) \leq f(\mathbf{x}_i^{(t)}), \\ \mathbf{x}_i^{(t)}, & \text{sicer,} \end{cases}$$

kjer se v naslednjo generacijo  $(t + 1)$  prenese boljši izmed njiju, tj.  $\mathbf{x}_i^{(t+1)}$ . Nastavitve algoritma DE so bile tekom preizkušanj nastavljen, kot prikazuje tabela 15. Algoritem 4

prikazuje sintezo algoritma DE in SNN, pri čemer opominjamo na razliko med in-silico simulacijami in RTC-SNN elektronskim vezjem, slednje za namen ponastavitve membranskih potencialov izkorišča pavzo za izpraznitev kondenzatorjev, medtem ko in-silico simulacije pavze ne izkoriščajo; indeksiranje pričnemo z 1 (MATLAB stil) in ne 0 (npr. Python, C).

Tabela 15: Nadzorni parametri DE

Nastavitev	Oznaka	Vrednost
Dimenzija	$nDIM$	20
Maksimalno št. generacij	$nGEN$	100
Velikost populacije	$nPOP$	50
Skalirni faktor	$F$	[0,2, 0,8]
Verjetnost križanja	$CR$	0,2
Simulacijske limite kapacitivnosti	$C_{min}, C_{max}$	0,1 nF, 1 mF
Kapacitivnost* nevrona	$C_{min}, C_{max}$	1 nF, 1 $\mu$ F

Opombe: Limite kapacitivnosti\* se nanašajo na in-silico simulacije; optimalna vrednost kapacitivnosti, kot to pokažejo simulacije, je nato uporabljena kot sidro za nastavitev kapacitivnosti RTC-SNN.

Ocenitvena funkcija  $ff\_val$  je bila pri preizkusu koncepta in preizkusih RTC-SNN+DE nastavljena kot:

$$ff\_val = 40 - \varepsilon,$$

pri čemer je  $\varepsilon$  označevala število pravilno klasificiranih primerkov znotraj enega DE posameznika. Pri preizkusih je bilo uporabljenih natanko 40 primerkov, kar posledično pomeni, da je teoretično najboljša vrednost ocenitvene funkcije še vedno nenegativna. Ocenitvena funkcija  $ff\_val$  pri trgovanju s SNN+DE je bila podana kot:

$$ff\_val = 10e^6 - \delta,$$

pri čemer je  $\delta$  označevala končno vrednost portfelja. Višja kot je bila  $\delta$ , nižja je bila  $ff\_val$  in posledično tem boljše so bile rešitve. Vrednost  $10e^6$  je bila nastavljena eksperimentalno tako, da je vedno zagotavljala pozitivne vrednosti  $ff\_val$ .

#### 4.4.1 Simulacije in-silico SNN+DE – poenostavljena zbirka podatkov IRIS

Algoritem DE (oz. katerikoli optimizacijski algoritem) je lahko zelo uporabno orodje za ugotavljanje relacij med nevroni in plastmi, optimalno rešitev pa lahko uporabimo tudi kot smerokaz za vzvratno razširjanje (indikator, kam mora učenje konvergirati). Preizkus koncepta s SNN+DE je bil izveden na enotnem (splošnem) modelu, na primeru poenostavljene zbirke podatkov IRIS. Napovedovanje je zaradi preizkušanja koncepta potekalo na enakih enotah kot učenje (delitve na učni in testni vzorec nismo uporabili). Posamezniki pri simulacijah in-silico SNN+DE sledijo predstavitvi posameznikov z  $nDIM = 20$ , kot sledi:

$$\mathbf{x}_i^{(t)} = \langle M_{i1}^{(t)}, M_{i2}^{(t)}, \dots, M_{i19}^{(t)}, C_i^{(t)} \rangle,$$

pri čemer je število sinaps  $M_{ij}^{(t)}$  podano kot:

$$nSim^{(hid_1)} = 3 \cdot 3 = 9,$$

$$nSim^{(hid_2)} = 3 \cdot 2 = 6,$$

$$nSim^{(out)} = 2 \cdot 2 = 4,$$

kar znaša skupaj  $9 + 6 + 4 = 19$  sinaps (za celotno SNN), dodatna dimenzija pa je namenjena za kapacitivnost  $C_i^{(t)}$ . Tako predstavljeni posamezniki so podobno podvrženi mutaciji, križanju in selekciji. Uporabljena zbirka podatkov je identična zbirki iz preizkusov z RTC-SNN elektronskim vezjem. Nadzorni parametri so podani v tabeli 16.

Tabela 16: Nadzorni parametri simulacije in-silico SNN+DE

Nastavitev	Oznaka	Vrednost
Arhitektura SNN		3 – 2 – 2
Učni algoritem		DE
Limite dig. pot. (sinaps)	$M_{min}, M_{max}$	1 k $\Omega$ , 100 k $\Omega$
Časovna konstanta	$dt$	50 $\mu$ s
Simulacijska dolžina	$sim\_len$	61.400 $\cdot dt$ (3,070 s)
Kapacitivnost nevrona	$C$	35 pF
Potencial praga	$\zeta$	500 mV
Mirovni potencial	$u_{rest}$	0 V
Presinaptični potencial	$u_{presynaptic}$	5 V
Refraktorska perioda	$R_p$	3 $\cdot dt$
Velikost učnega/testnega vzorca		40
Št. neodvisnih zagonov	$N$	10

Opombe: \*=minimalna memristanca odvisna od proizvajalca, variira v rangi od 50 – 100  $\Omega$ . min=minimum, max=maksimum.

Rezultati učenja z algoritmom DE so upodobljeni na sliki 20. Sprva je bilo izvedenih 10 naključnih zagonov, katerih rezultati so prikazani črtkano. Iz vseh zagonov je razvidno konstantno upadanje napake. Ugotavljamo, da večina zagonov po 100 generacijah že dosega napako manjšo od 5, nekateri zagoni dosežejo celo napako enako 0. Smatramo, da je učni problem za algoritem DE razmeroma enostaven. Odebeljeno je prikazan eden izmed zagonov, ki ga podrobneje preučimo. Ta v prvi polovici optimizacije (po uvodni nastavitvi) doseže dvojno izboljšanje vrednosti ocenitvene funkcije  $ff\_best$ , napaka iz začetnih 21 nepravilno klasificiranih enot upade na 15. Nekaj časa se najboljša vrednost ocenitvene funkcije ne izboljša, po približno 75 generacijah pa močno upade, tj. doseže nepravilno klasificiranje le 2 enot (tako ostane do konca).



**Algoritem 4: Nadgradnja učnega algoritma SNN+DE**

```

UVODNO NASTAVI verigo vhodnih, vmesnih in izhodnih sinaps;
UVODNO NASTAVI poenostavljeno zbirko podatkov  $\mathbf{Z}'$ ;
UVODNO NASTAVI generatorje signala in pripadajoče časovnike;
/* Začetek uvodne nastavitve algoritma DE */
For  $i$  od 1 do št.  $nPOP$ :
    UVODNO NASTAVI vrednosti sinaps na naklj. vred. med spodnjo in zgornjo limito;
    POSODOBI memristorje;
    For  $j$  od 1 do št.  $inštanc$  učenja:
        PONASTAVI kazalnike; // ponastavitev
        RAZŠIRJAJ primerek  $j$ ; // dolžina predv.  $sim\_len$ 
        PREKINI razširjanje*; // pavza za umiritev
    EndFor
     $ff\_val[i]$  <- IZRAČUNAJ vrednost ocenitvene funk.; // ovrednoti rešitve
EndFor
 $ff\_best$  <- EKSTRAHIRAJ  $\min(ff\_val)$ ; // trenutno najboljša rešitev


/* Začetek glavnega dela algoritma DE */
For  $t$  od 1 do št.  $nGEN$  učenja: // št. generacij
    For  $i$  od 1 do št.  $nPOP$ : // velikost populacije
        For  $j$  od 1 do št.  $nDIM$ :
            /* Mutacija */
            IZBERI naključne indekse  $r0, r1, r2$ ; //  $r0 \neq r1 \neq r2 \neq i$ , uniform
            IZRAČUNAJ naključno vrednost  $F$ ; // skalirni faktor, uniform
            IZRAČUNAJ  $\mathbf{u}_i^{(t)}$ ; // mutacija
            OMEJI  $\mathbf{u}_i^{(t)}$  med spodnjo in zgornjo limito; //  $M_{min}, M_{max}, C_{min}, C_{max}$ 
        EndFor

        NAKLJUČNO IZBERI indeks  $j_{rand}$ ;
        For  $j$  od 1 do št.  $nDIM$ :
            /* Križanje */
            If  $rand_j(0,1) \leq CR \vee j = j_{rand}$ :
                 $\mathbf{w}_{i,j}^{(t)} = \mathbf{u}_{i,j}^{(t)}$ ;
            Else
                 $\mathbf{w}_{i,j}^{(t)} = \mathbf{x}_{i,j}^{(t)}$ ;
            EndFor

        POSODOBI memristorje z  $\mathbf{w}_i^{(t)}$ ;
         $ff\_val[i]$  <- OVREDNOTI poskusne rešitve  $\mathbf{w}_i^{(t)}$ ; //  $sim\_len$ , za vsak primerek
        POSODOBI  $ff\_best$ ;
        If  $(\mathbf{w}_i^{(t)}) \leq f(\mathbf{x}_i^{(t)})$ :
             $\mathbf{x}_i^{(t+1)} = \mathbf{w}_i^{(t)}$ ;
        Else
             $\mathbf{x}_i^{(t+1)} = \mathbf{x}_i^{(t)}$ ;
        EndFor
    EndFor
EndFor

```

Slika 20: Napredovanje najboljših vrednosti ocenitvene funkcije  $ff\_best$  z naraščanjem števila generacij, simulacije in-silico SNN+DE



Opomba: Črtkano je prikazanih 10 naključnih zagonov, odebjeljeno je prikazan primer, ki ga v nadaljevanju podrobneje preučimo.

Rezultate odebeljenega zagona shranimo v obliki kontingenčne tabele, prikazane v tabeli 17. Ta prikazuje klasifikacijsko porazdelitev primerkov za dan zagon, s priklicanimi utežmi SNN, ki zagotavljajo najboljšo vrednost ocenitvene funkcije.

Tabela 17: Rezultati napovedovanja na učnem vzorcu poenostavljene zbirke podatkov IRIS, kontingenčna tabela, simulacije in-silico SNN+DE

	Dejanski razred 1 ('setosa')	Dejanski razred 2 ('virginica')
Napovedan razred 1 ('setosa')	20 (TN)	0 (FN)
Napovedan razred 2 ('virginica')	0 (FP)	18* (TP)

Opomba: \*=neopredeljeno, pri SNN se lahko zgodi, da imajo izhodni nevroni identično število izhodnih pulzov, kar pomeni, da glede na število impulzov ne moremo klasificirati, h kateremu razredu primerek spada. Pri poskusnem zagonu zabeležimo dva (2) tovrstna primerka. Hkrati omenimo, da bi dodatna (detajlna) optimizacija (dodatno število generacij) zadeve še izboljšala.

Simulacije in-silico kažejo, da je SNN+DE uporabno klasifikacijsko orodje. Čeprav optimizacijska metoda ne deluje sprotno (kot npr. vzvratno razširjanje), je lahko zelo uporabna za ugotavljanje splošnih zakonitosti SNN mrež in pristopa delovanja SNN mrež. Seveda moramo upoštevati, da je algoritem DE splošni optimizacijski algoritem, zato pristop SNN+DE ne sledi »pravemu« učenemu postopku bioloških možganov.

V okviru testiranj smo izvedli tudi analizo časovne kompleksnosti. Zaradi dolgotrajnih postopkov učenja SNN+DE smo programski del SNN v orodju MATLAB preuredili v obliko, primerno za večnitno vzporedno izvajanje. Tu je bila posebno primerna funkcija »*pagefun*« in vzporedna zanka »*parfor*«. Rezultate analize časovne zahtevnosti smo zajeli v tabeli 18.

Tabela 18: Časovna zahtevnost izvajanja učenja ter testiranja SNN

		Delovni računalnik HP 400 G4 MT	Strežniški računalnik HP ProLiant
SNN+DE	Povp.	0:55:01	1:29:18
	Min.	0:54:46	1:28:41
	Maks.	0:56:23	1:30:07
	Stdev	0:00:28	0:00:26
	Skew	3,110	0,659

Opombe: Postopek SNN+DE je podan v formatu  $hh:mm:ss$ ,  $N = 10$ . Stdev=standardni odklon, skew=koeficient asimetrije.

Sodeč po tabeli 18 ugotavljamo, da je delovni računalnik navkljub nižjemu številu niti hitreje izračunal celotno učenje SNN+DE. Smatramo, da je temu tako deloma zaradi višje delovne frekvence procesorja in pomnilnika RAM, deloma pa tudi zaradi zmanjšane časa komuniciranja med nitmi. Nadaljnja preizkušanja smo glede na pridobljene rezultate opravili na delovnem računalniku.

#### 4.4.2 Preizkus RTC-SNN+DE – poenostavljena zbirka podatkov IRIS

Predstavitev posameznikov smo pri preizkušanju RTC-SNN+DE nekoliko preuredili. Zaradi fiksne nastavitve kapacitivnosti  $C$  elektronskega vezja, ki je v živo nismo spreminjali, smo dimenzije problema na fizičnem elektronskem vezju zmanjšali na  $nDIM = 19$ , kot sledi:

$$\mathbf{x}_i^{(t)} = \langle M_{i1}^{(t)}, M_{i2}^{(t)}, \dots, M_{i19}^{(t)} \rangle.$$

Kljub tej spremembi dimenzije pa so operacije mutacije, križanja in selekcije ostale podobne kot pri preizkušanjih in-silico, identična je ostala tudi uporabljena zbirka podatkov. Kapacitivnosti nevronov  $C$  smo po vzoru simulacij in-silico (optimalne nastavitve) fiksno nastavili na vrednost  $C = 0,1$  uF. Ostale nadzorne parametre RTC-SNN+DE prikazuje tabela 19.


Tabela 19: Nadzorni parametri RTC-SNN+DE

Nastavitev	Oznaka	Vrednost
Arhitektura SNN		3 – 2 – 2
Učni algoritem		DE
Limite dig. pot. (sinaps)	$M_{min}, M_{max}$	*, 100 k $\Omega$
Časovna konstanta	$dt$	10 $\mu$ s
Simulacijska dolžina	$sim\_len$	160,000 $\cdot dt$ (1,6 s)
Kapacitivnost nevrona	$C$	1 $\mu$ F
Potencial praga	$\zeta$	500 mV
Mirovni potencial	$u_{rest}$	0 V
Presinaptični potencial	$u_{presynaptic}$	5 V
Refraktorska perioda	$R_p$	10 $\mu$ s
Velikost učnega/testnega vzorca		40
Št. neodvisnih zagonov	$N$	1

Opombe: \*=minimalna memristanca odvisna od proizvajalca, variira v rangi od 50 do 100  $\Omega$ . min=minimum, max=maksimum.

Rezultati RTC-SNN+DE elektronskega vezja se niso pokazali tako blesteče kot in-silico simulacije RTC-SNN, kar je bilo pričakovano. RTC-SNN+DE namreč ni bilo zasnovano, da bi omogočalo sprotno spreminjanje kapacitivnosti  $C$ , zato smo slednjo izbrali eksperimentalno (ta pa lahko dejansko bistveno odstopa od optimalne vrednosti). Dodatno bi želeli izpostaviti visoke tolerance digitalnih potenciometrov, ki lahko bolj ali manj odstopajo od zelenih vrednosti. Kar zelo bode v oči, je tudi zahtevna časovna kompleksnost. Gabariti RTC-SNN+DE elektronskega vezja so bili namreč izbrani tako, da vezje omogoča enostavno sledljivost signalov in transparentnost razširjanja, kar posledično zahteva dolgotrajnejše časovne konstante nevronov in sinaps. Slika 21 prikazuje napredovanje najboljših vrednosti ocenitvene funkcije.

Slika 21: Napredovanje najboljših vrednosti ocenitvene funkcije v odvisnosti od naraščanja števila generacij, RTC-SNN+DE



Zaradi počasnejšega napredovanja najboljših vrednosti smo izvedli višje število generacij. Ne samo, da je bilo počasnejše samo napredovanje, veliko slabše se je RTC-SNN+DE odrezala tudi pri uvodni nastavitvi, tj. prvi (začetni) vrednosti napake. Ta je znašala 25, kar je bistveno več kot pri simulacijah in-silico SNN+DE. Razlog za slabši začetek je v tem, da je bilo pri večini primerkov enakovredno število impulzov zunanje plasti SNN, kar je mikrokrmilnik klasificiral kot signal FP, tj. kot napako. Kljub temu smo ugotovili, da je dobra uteženost SNN po naključni razvrstitvi uteži ključna za napredovanje (ne samo da je ključna, to je celo ena izmed bistvenih zahtev; alternativno bi namreč pomenilo, npr. da bi se vseskozi na enem izmed izhodnih nevronov konstantno pojavljalo višje število impulzov, kar bi na dolgi rok definiralo nagnjenost v eno smer). Zaradi tega smo kapacitivnosti zunanjih nevronov pred vsakim eksperimentom ročno utežili z dodajanjem ali odvzemanjem kapacitivnosti (kondenzatorjev) nevrone.

Tabela 20: Rezultati napovedovanja na učnem vzorcu poenostavljene zbirke podatkov IRIS, kontingenčna tabela, RTC-SNN+DE

	Dejanski razred 1 ('setosa')	Dejanski razred 2 ('virginica')
Napovedan razred 1 ('setosa')	19 (TN)	16 (FN)
Napovedan razred 2 ('virginica')	0 (FP)	3* (TP)

Opomba: \*=neopredeljeno, pri SNN se lahko zgodi, da imajo izhodni nevroni identično število izhodnih pulzov, kar pomeni, da glede na število impulzov ne moremo klasificirati, h kateremu razredu primerka spada. Pri poskusnem zagonu zabeležimo dva (2) tovrstna primerka. Hkrati omenimo, da bi dodatna (detajlna) optimizacija (dodatno število generacij) zadeve še izboljšala.

#### 4.4.3 Simulacije in-silico SNN+DE – trgovanje s SNN

Po opravljenih simulacijah na zbirki IRIS smo opravili tudi simulacije in-silico SNN+DE, ki so bile namenjene za problem trgovanja in posledično preverjanju veljavnosti prvega dela hipoteze H2 (umestitev SNN kot trgovalne strategije). Pri tem je treba poudariti, da implementirano trgovanje ni bilo izvedeno online, tj. s sprotnim vsakodnevnim posodabljanjem, temveč smo klasično učne primerke uporabili za »in-sample« učenje modela, testne pa za »out-of-sample« trgovanje. Po končanem učenju je model ostal fiksni.

Posamezniki SNN+DE so bili na problemu trgovanja predstavljeni kot vektor:

$$\mathbf{x}_i^{(t)} = \langle M_{i1}^{(t)}, M_{i2}^{(t)}, \dots, M_{inDIM}^{(t)}, C_i^{(t)} \rangle,$$

pri čemer je znašala dimenzija  $nDIM = 2071$ . Dimenzija je bila izračunana kot vsota števila sinaps v modelu SNN+DE, ki je znašala:

$$nSin^{(hid)} = 43 \cdot 45 = 1.935,$$

$$nSin^{(out)} = 45 \cdot 3 = 135,$$

pri čemer  $nSin^{(hid)}$  predstavlja število sinaps skrite plasti,  $nSin^{(out)}$  pa število sinaps izhodne plasti. Skupaj znaša  $nSin^{(hid)} + nSin^{(out)} = 1.935 + 135 = 2.070$ , k temu pa je dodana še dodatna dimenzija za kapacitivnost  $C_i^{(t)}$ . Ostali nadzorni parametri so zajeti v tabeli 21.

Rezultate smo znova predstavili grafično, pri čemer smo podali graf desetih neodvisnih zagonov vrednosti portfelja in graf upadanja najboljše vrednosti ocenitvene funkcije. Slika 22 prikazuje upadanje najboljše ocenitvene vrednosti desetih neodvisnih zagonov.


Testiranja in-silico SNN+DE so bila izredno zamudna, zato smo število generacij  $nGEN = 100$  ohranili iz nastavitve testiranja SNN+m. STDP (kljub zavedanju, da je  $nGEN = 100$  veliko premalo). Posledično se SNN ni optimalno prilagodila transformaciji vhodnih v izhodne podatke. Kljub temu moramo priznati, da je dosegla uporabne trgovalne signale tipa kupi in tipa zadrži, medtem ko trgovalnih signalov tipa prodaj mreža ni dosegla v nobenem zagonu. To pomeni, da algoritem SNN+DE v celotnem opazovanem obdobju noben krat ni prodal

kakršnegakoli instrumenta, posledično pa je udejstvovanje tržne kapitalizacije simulacij in-silico SNN+DE zelo podobno udejstvovanju delniškega indeksa.


Tabela 21: Nadzorni parametri simulacij in-silico SNN+DE

Nastavitev	Oznaka	Vrednost
Arhitektura SNN		43 – 45 – 3
Učni algoritem		DE
Limite dig. pot. (sinaps)	$M_{min}, M_{max}$	100 $\Omega$ , 100 M $\Omega$
Časovna konstanta	$dt$	10 $\mu$ s
Simulacijska dolžina	$sim\_len$	$200 \cdot dt$ (2 ms)
Potencial praga	$\zeta$	-55 mV
Mirovni potencial	$u_{rest}$	-70 mV
Presinaptični potencial	$u_{presynaptic}$	30 mV
Kapacitivnost nevrona	$C_{min}, C_{max}$	1 nF, 1 $\mu$ F
Puščanje (lekaža)	$L_f$	0,27
Refraktorska perioda	$R_p$	$3 \cdot dt$
Velikost učnega vzorca		1748
Velikost testnega vzorca		874
Št. neodvisnih zagonov	$N$	10
Dimenzija	$nDIM$	2071

Slika 22: Napredovanje najboljše vrednosti ocenitvene funkcije v odvisnosti od naraščanja števila generacij, simulacije in-silico SNN+DE,  $N = 10$  neodvisnih zagonov



Slika 23: Tržna kapitalizacija v odvisnosti od trgovalnih dni, simulacije in-silico SNN+DE



Opomba: Ostalih devet zagonov je zelo podobnih, saj so razlike med posameznimi zagoni tako majhne, da se rezultati med njimi le minimalno razlikujejo (zato jih ne prikazujemo).

Zelo zanimivo je dejstvo, da so razlike med neodvisnimi zagoni tako majhne navkljub medsebojni neodvisnosti. Predvidevamo, da je to zaradi sledečega fenomena. Indeks sam po sebi v opazovani dobi izkazuje pozitivni donos, kar mreži SNN poda ugoden signal – zato je učinkovito, če čim hitreje poda trgovalne signale za nakup, kajti v tem primeru bo donos sledil indeksu, kar bo donosnejše od držanja prostih denarnih sredstev. To mreži SNN predstavlja hitro konvergenco (predvidevamo, da v lokalni optimum), medtem ko se do globlje in učinkovitejše rešitve, tudi z vključevanjem prodajnih signalov, znotraj števila generacij ne dokoplje.

Generiranje izključno dveh tipov trgovalnih signalov je posledica nezadostnega učenja SNN+DE. Dimenzija problema, tj.  $nDIM = 2071$ , uvršča tak problem med izredno zahtevne in zahteva obilo več učenja kot dejansko uporabljenih  $nGEN = 100$ . Kljub temu gre za izredno enostavno arhitekturo SNN, spomnimo, da obravnavamo le 43 vhodnih nevronov, 45 skritih in 3 izhodne, kar je glede na biološke možgane zanemarljivo malo. A vendarle dimenzija, s tem pa tudi težavnost problema, raste eksponentno z dodajanjem nevronov, kar napeljuje na misel, da običajni optimizacijski postopki (kot npr. DE je) niso primerni za učenje mrež SNN višjih dimenzij. Poleg tega ugotavljamo, da optimizacijski algoritem obravnava vse primerke kot celoto, kar pomeni, da je treba za preizkus ene testne rešitve obravnavati celotno zbirko podatkov. Posledično je tak postopek časovno in prostorsko neučinkovit. Zato je nujen razvoj učnega algoritma, ki omogoča popolnoma sprotno (vzporedno) in neodvisno učenje (kar m. STDP je). Pod »sprotnim« mislimo na učenje, ki se dogaja že znotraj razširjanja posameznih primerkov, pod »neodvisnim« pa, da poteka učenje ločeno od nevrona do nevrona. Pri večplastnem razširjanju se namreč pojavi fenomen t. i. sklopljenosti (odvisnosti naslednje plasti od prejšnje), kar praktično pomeni, da četudi je npr. 2070 uteži nastavljenih ustrezno, 1 utež pa neustrezno, ta neustreznost utegne bistveno poslabšati celotno sliko. Optimizacijski algoritem sicer uteži obravnava kot popolnoma ločene enote, a vendarle verjetnost, da bo ta ustrezno zadel nastavitve vseh uteži znotraj testne rešitve, upada eksponentno z naraščanjem dimenzije.

Zatorej je deloma nujno ločiti učenje posameznega nevrona od ostale celote (kar bi v DE smislu pomenilo, da bi namesto ene oz. skupne, ocenitvene funkcije, obstajala ocenitvena funkcija za vsak posamezen nevron posebej). Posledično bi bilo smiselno implementirati tudi vzporedno učenje, tj. učenje v realnem času, kar bi pomenilo učenje (spreminjanje uteži SNN) znotraj razširjanja enega primerka. To bi omogočilo cel spekter nadaljnjih eksperimentiranj tudi na namenski strojni opremi (FPGA) z uporabo celoštevilске aritmetike.

Seveda bi taka »na nevrona osredinjena« metoda prinesla številne druge težave, predvsem pomanjkanje širše slike (angl. big picture), kar naravno kliče po kompromisu med obema idejama. Tu se poraja več idej:

- Vsakemu izhodnemu nevronu določimo posamično ocenitveno funkcijo; tako lahko posamezni primerek »privežemo« na ustrezen izhodni nevron, a pri tem pristopu naletimo na problem parceliranosti uteži k dotičnemu nevronu, tj. kateri nevron v prejšnjih plasteh spada h kateremu izhodnemu nevronu (paziti je treba na identičnost dimenzij).
- Vsaki izmed plasti SNN določimo posamično ocenitveno funkcijo; tako imamo učinkovit pregled nad lokalnim in regijskim dogajanjem, a znova pomanjkljiv nadzor nad globalnim dogajanjem. V primeru prilagojenega vezja RTC lahko teoretično posamičnemu primerku določimo celo posamično valovno dolžino, s čimer dosežemo hkratno razširjanje večjega števila informacij.
- V glavnini postopek učenja prepustimo osredotočenemu m. STDP, za vsako plast določimo le manjše korekcijske faktorje, ki jih globalno nadzoruje optimizacijski algoritem. To se zdi smiselna ideja, ki sicer ne sledi popolnoma originalni zasnovi Hebbovega učenja, a opogumlja vprašanje, koliko nadzorovanega nadzora nad učenjem pa je sploh smiselnega. Tudi korenček in palica le generalno nakazujeta polariteto učenja, nimata pa neposrednega odgovora, kako točno nastaviti posamezne uteži sinaps.

Kljub nasprotnim pričakovanjem so simulacije SNN+DE dosegle pozitivni izkupiček glede na vložena prosta denarna sredstva. V povprečju ( $N = 10$ ) je SNN+DE dosegla končno vrednost portfelja 279.307 Eur, s standardnim odklonom približno 353 Eur, kar pomeni 3,45 % dobiček. Navkljub ugodnemu trgovanju pa SNN+DE ni izkazala prodajnih trgovalnih signalov pred začetkom pandemične krize, s čimer bi močno omilila izgube, kar je skupno vrednost portfelja proti koncu trgovalne periode močno ohromilo.

## 4.5 Diskusija

Sestavljeno RTC-SNN elektronsko vezje je v veliki meri pripomoglo k skupnemu razumevanju SNN nevronske mreže. Najpomembnejša vsebinska ugotovitev pri tem je, da se SNN da uporabiti kot ITS. Z eksperimenti smo pokazali, da lahko SNN kot ITS preseže vhodna prosta denarna sredstva, upoštevajoč tudi transakcijske stroške. Ugotavljamo pa, da trgovanje s SNN ni tako dovršeno kot trgovanje z LSTM, še posebej v časih medvedjega trga. Razvoj mreže SNN, s tem pa tudi učnih algoritmov je v polnem razmahu, kar pomeni, da lahko kaj kmalu pričakujemo večje ali manjše znanstvene preboje na tem področju. Aplikacija v tej doktorski nalogi je vsekakor pokazala, da so SNN v bodoče lahko resno orodje za kakršnekoli



klasifikacijske probleme, tudi avtomatizirana trgovanja, in da se izvajanje teh s pomočjo namenske strojne opreme da izredno pohitrili. Vsebinsko se zgrajeno analogno vezje od digitalnega pomembno razlikuje po:

1. Prilagodljivosti oblike (strukture) impulza, kar pomeni, da analogno vezje lahko prenaša signal poljubne oblike (digitalno vezje omogoča prenašanje izključno binarnih vzorcev, kar je v primerjavi z analogno izvedbo precejšnji manko). Prilagodljivost nosilnega signala je lahko v omejeni obliki del učnega postopka vzratnega razširjanja, kar pripomore k fleksibilnosti SNN.
2. Poljubnosti intenzitete impulza, kar pomeni, da lahko analogno vezje prenaša svetlobne impulze različnih intenzitet (magnitud). Različno intenziteto enostavno kontroliramo z napajalno napetostjo optičnega oddajnika. V nadalje kličemo po implementaciji algoritma vzratnega razširjanja, ki bi poleg upornosti sinaps (in oblike signala) prilagajal tudi intenziteto.
3. Prenosu svetlobnega signala, ki dobro posnema prenašanje informacij bioloških možganov. V bioloških možganih se informacije pretakajo preko sproščanja nevroprenašalcev, v naši aplikaciji preko fotonov. Obstaja tudi možnost prenosa svetlobnega signala različne valovne dolžine, kar utegne simulirati točen tip nevroprenašalca. To bi zasnovano vezje še dodatno približalo dejanskim biološkim možganom.
4. Časovnosti impulza, glede na to, da operiramo z analognimi svetlobnimi signali, katerim lahko prilagajamo njihovo obliko, lahko enostavno spreminjamo tudi njihovo časovno distribucijo.

Ugotavljamo, da lahko strukturo (lastnosti) svetlobnega signala opišemo z vsaj štirimi dimenzijami: (1) obliko, (2) intenziteto, (3) časovnim trajanjem in (4) valovno dolžino. Povrh se vse naštetosti lastnosti dajo enostavno prilagajati v okviru naprednega učnega algoritma.

Končno opravimo tudi primerjalno (statistično) analizo enakovrednosti uporabljenih AI metod. Na podlagi vzorca  $N = 10$  izvedemo dva statistična testa, tj. parametrični t-test in neparametrični Mann-Whitney test. Rezultate v obliki p-vrednosti zapišemo v tabelo 22, pri obeh testih izvedemo Holm-Bonferroni popravek (Holm, 1979), pri tem uporabimo sledeče formule:

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s^2 \cdot \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$$

pri čemer  $\bar{x}_1$  in  $\bar{x}_2$  predstavljata srednje vrednosti dveh skupin,  $n_1$  in  $n_2$  sta velikost vzorca,  $s^2$  pa je kompozitna varianca obeh vzorcev. Mann-Whitney test izračunamo po obrazcih:

$$U_1 = n_1 \cdot n_2 + \frac{n_1 \cdot (n_1 + 1)}{2} - R_1,$$

$$U_2 = n_1 \cdot n_2 + \frac{n_2 \cdot (n_2 + 1)}{2} - R_2.$$

kjer  $n_1$  in  $n_2$  predstavljata velikost vzorcev,  $R_1$  in  $R_2$  pa sta vsoti rangov. Korekcijo Holm-Bonferroni izvedemo tako, da izračunane p-vrednosti uredimo v ranžirno vrsto (za vsak test

posebej). Najnižjo vrednost p-statistike pomnožimo s številom testov (v tem primeru  $n = 6$ ), drugo najnižjo s  $n - 1 = 5, \dots$ , najnižjo p-vrednost z  $n - 5 = 1$ .

Sodeč po pridobljenih rezultatih sklepamo, da med metodami LSTM1, LSTM2 in SNN+m. STDP ne obstajajo bistvene statistične razlike. Dodatno sklepamo, da se rezultati trgovanja SNN+DE bistveno razlikujejo od vseh ostalih metod AI, a moramo pri tem opozoriti, da je to posledica zelo nizke variance končnih vrednosti tega portfelja.

Tabela 22: Primerjava med metodama AI po parametričnem t-testu (levo) in neparametričnem Mann-Whitney testu (desno, oboje p-vrednosti), popravljeno po Holm-Bonferroni metodi,  $N = 10$

	<b>LSTM1</b>	<b>LSTM2</b>	<b>SNN+m. STDP</b>	<b>SNN+DE</b>
<b>LSTM1</b>	x	0,585/0,678	0,660/0,723	$6,192^{-20}/7,184^{-4}$
<b>LSTM2</b>	-	x	0,912/0,872	$1,985^{-8}/5,905^{-4}$
<b>SNN+m. STDP</b>	-	-	x	$1,316^{-6}/5,905^{-4}$
<b>SNN+DE</b>	-	-	-	x

Opombe: Za izračun so uporabljene končne vrednosti portfelja. Prikazane so pripadajoče p-vrednosti. Sprejmemo sklep, da so LSTM1, LSTM2 in SNN+m. STDP enakovredne, SNN+DE pa se od vseh razlikuje.

Na podlagi eksperimentalnih preizkusov SNN+m. STDP in SNN+DE in na podlagi pridobljenih vzorčnih podatkov ne moremo zavrniti prvega dela hipoteze H2. Praktično to pomeni, da lahko SNN kot predstavnico tretje generacije nevronske mreže kot aktivno ITS implementiramo v MTS (pri SNN nismo osredotočeni na nujnost prekašanja klasičnih ITS). Na podlagi eksperimentalnega preizkusa FPGA-SNN+m. STDP in na podlagi pridobljenih vzorčnih podatkov ne moremo zavrniti niti drugega dela hipoteze H2, kar pomeni, da lahko osnovno logiko SNN konfiguriramo v formatu, primernem za FPGA. Na FPGA je procesiranje SNN, sodeč po opravljenih časovnih merjenjih, veliko hitrejše, odzivni časi pa posledično veliko manjši.

Odgovor na vprašanje zakaj lahko implementiramo SNN kot ITS v MTS je preprosto, sloni pa na domnevi, da lahko SNN implementiramo za reševanje klasifikacijskega problema. Predpostavimo lahko, da je število impulzov na izhodnih nevronih v času simulacijske dolžine odločujoč pokazatelj aktivnosti razreda, in da vhodni primerek spada k razredu z najvišjo aktivnostjo. Tako na zelo preprost način pridobimo SNN za klasifikacijski problem, katerega lahko umestimo kot ITS v MTS. Kot so pokazali nadaljnji eksperimenti na FPGA, lahko tovrstno logiko konfiguriramo tudi v obliki celoštevilске aritmetike in jo kot tako poženemo na FPGA.

## 5 SKLEP

Implementirali in izvedli smo eksperimentalna preizkušanja portfeljskega trgovanja na nemškem borznem trgu z obetavnimi trgovalnimi strategijami na osnovi AI (sprotno posodabljaljivim enotnim in posamičnim LSTM modelom, SNN+m. STDP ter SNN+DE modelom). Rezultate teh smo primerjali s klasičnimi trgovalnimi strategijami. Pričakovali smo, da bo mogoče vse naštetih metode AI uporabiti za aktivno trgovanje na delniškem trgu in da bo globoka LSTM, ki je posebej prilagojena za analizo zaporednih podatkov, najuspešnejša med njimi. Ugotovili smo, da je trgovanje z naštetimi metodami AI možno, a da ne obstajajo bistvene razlike med metodami LSTM1, LSTM2, SNN+m. STDP. Le postopek SNN+DE, ki smo ga predlagali in implementirali v tej doktorski disertaciji, nekoliko odstopa od konkurentov in zaenkrat deluje manj učinkovito.

Teze doktorske disertacije na podlagi vzorčnih podatkov ne moremo zavrniti. Metode AI lahko uporabimo kot trgovalne strategije, v obliki klasifikacijskega problema, pri tem pa rezultati teh lahko prekašajo klasične trgovalne strategije. Poudarjamo, da je zaradi stohastičnosti metod AI pomembno izvesti več ločenih eksperimentov. Na podlagi vzorčnih rezultatov in opravljenih eksperimentov ne moremo zavrniti hipoteze H1. LSTM kot trgovalna strategija lahko prekaša klasične trgovalne strategije, tudi pasivno strategijo, ki se je izkazala kot najbolj izstopajoča. Kljub temu LSTM avtomatično ne zagotavlja uspeha, temveč je rezultat LSTM kot trgovalne strategije močno odvisen od zasnove rešitve problema. Hipoteze H2 na podlagi vzorčnih podatkov ne moremo zavrniti. SNN smo uspešno integrirali v mehanski trgovalni sistem kot trgovalno strategijo in jo kot tako implementirali tudi na namenski strojni opremi, ki bistveno izboljšuje časovno kompleksnost izvajanja. Pri tem je SNN generirala trgovalne signale v odvisnosti od vhodnih podatkov.

Učenje LSTM je časovno potratno in kliče po izboljšavah. Velja pripomniti, da je dolgotrajno le učenje, ko pa je model enkrat izdelan, LSTM veliko hitreje izraža osnovne klasifikacijske trgovalne signale (kupi, zadrži in prodaj). V najboljšem primeru (izmed desetih naključnih zagonov) tako enotna kakor tudi posamična LSTM ITS lahko premagata pasivno ITS, ki se izkaže kot najbolj donosna med klasičnimi. V povprečju (prav tako na osnovi desetih zagonov) se oba modela izkažeta kot solidna. Enotna LSTM ITS je nekoliko robustnejša in posledično manj variabilna; posamična LSTM ITS je bolj variabilna in posledično dosega višje možnosti za končni donos. Pomembna vsebinska ugotovitev, ki se pojavi pri tem, je, da so v povprečju donosnosti enotnega in posamičnega modela identične. Dejstvo lahko interpretiramo kot eno izmed osnovnih značilnosti vlagateljev, tj. podvrženost bolj ali manj identičnim psihološkim nagnjenjem (učinkom). Izgleda, da ta nagnjenja zelo podobno vplivajo na vse vlagatelje, kar nadalje pomeni tudi, da podobno vplivajo na delnice v portfelju. Zatorej je vseeno, če se pri trgovanju različnih delnic (znotraj enakega ali enakovrednega trga) zanašamo na en (skupni) model ali kopico posameznih. Čeprav sta se enotni in posamični model izkazala kot zelo podobna, dajemo prednost enotnemu modelu, delno zaradi višje robustnosti in boljše napovedljivosti, delno pa tudi zaradi zmanjšane kompleksnosti procesiranja (z enim računalnikom lahko pokrijemo veliko širši spekter delnic). Pred praktično uporabo je seveda nujno razvrstiti raznorazne delnice (npr. spekter 1000 delnic) v nekaj osnovnih skupin, npr. malo tvegane, srednje tvegane, zelo tvegane ali pa npr. rastoča podjetja, zrela podjetja in

podjetja v zatonu. Uporaba algoritmov razvrščanja (angl. clustering) in selekcije značilk (D. Fister, Fister, et al., 2019; Vrbančič et al., 2018) sta lahko pri tem v pomoč, ob povišani kompleksnosti pa celo načrtovanje cevovoda (I. Fister, 2019).

Značilnost dobrega limitiranja izgub na medvedjem trgu, a slabšega izkoristka na bikovskem je bil v preteklosti za avtomatizirane trgovalne strategije že naslovljen. Kay (2019) je neposredno zapisal, da njegov predlagan algoritem zelo dobro omejuje izgube na medvedjih trgih in da se ne znajde najbolje v časih po recesiji (gospodarski ekspanziji). Zato predlaga, da je nujno identificirati aktualne gospodarske razmere in predlagan algoritem uporabiti tedaj, ko je to najbolj primerno (to pa seveda kliče k implementaciji dodatnega modela, ki bi deloval v časovnih obdobjih izven »pristojnosti« originalnega modela). Kay (2019) je med drugim v okviru svojih preizkušanj prav tako pokazal, da lahko trgovalne metode delujejo popolnoma neodvisno od gospodarskega trenda, tj. portfelj lahko doseže ničelne oz. celo negativne vrednosti bete  $\beta$ .

Da bi izboljšali trgovanje tako z enotnim kakor tudi posamičnim modelom, bi izvedli dodatne preizkuse s širšim naborom nadzornih parametrov. Prav tako bi v analizo poleg LSTM vključili tudi ograjene rekurentne enote (angl. Gated Recurrent Units, krajše GRU), za katere je znano podobno ogrodje kot LSTM, a hitrejše in učinkovitejše učenje. Pričakujemo, da bi dodatne (eksogene) aktualne informacije, npr. iz medijev, socialnih omrežij ali trgovalnih platform dodobra povečale uporabnost predlaganih modelov. Tovrstne (subjektivne) informacije, ki so velikokrat priča ekstremnim premikom na borzi, bi lahko vključili preko podpornih modelov (angl. support vs. confidence models), kot npr. I. Fister & Fister (2021). Analize sentimenta za uporabo v trgovalnih modelih so nazorno prikazane v (Day & Lee, 2016; Rao & Srivastava, 2012; Shi et al., 2021). Dodatno bi lahko izvedli več posameznih zagonov, npr. iz  $N = 10$  na  $N = 100$  ali celo  $N = 1000$  in se osredotočili tudi na druge finančne trge (ameriški, japonski) drugih finančnih instrumentov (obveznice, kriptovalute, surovine). Uporabnost implementiranih in preizkusnih modelov bi lahko dosegli z neposrednim interveniranjem na odprtem trgu (ne samo simuliranjem, temveč tudi z dejanskim trgovanjem z realnimi denarnimi sredstvi) ali v nekoliko blažji obliki – kot sistem priporočanja. Pri tem bi bilo treba seveda zagotoviti širokopasovno povezavo s spletom, časovne konstante pa bi se iz dneva morale znižale na minute ali celo sekunde (posledično bi se menjave iz več dni ali celo mesecev pomembno skrajšale tudi na nekaj ur, mogoče celo manj). Kot najpomembnejšo potencialno izboljšavo, ki bi jo bilo treba v prihodnosti dodatno nasloviti, navajamo izkoriščanje bikovskega trenda za oplemenitenje kapitalske vrednosti portfelja. Pričakujemo, da bi donosnost portfelja pomembno zrasla, če bi se osredotočili na omejevanje izgub na eni strani (kot do zdaj) ter dodatno izkoriščanje potencialnih naraščajočih trendov po drugi strani. Pri obvladovanju tveganj namreč ne govorimo samo o negativnih tveganjih, temveč tudi o pozitivnih. In če obstaja možnost, da delujemo boljše od pričakovane, slednje ne smemo izpustiti. Pričakujemo, da se beta  $\beta$  s tem ne bi smela bistveno povečati, temveč bi še naprej ostala neodvisna od dogodkov na borzi, le da bi namesto blagega naklona navzgor tokrat stavili na zmerni naklon.

Čeprav sta obe predstavljeni ogrodji z LSTM superiorni v najboljših primerih zagonov, pa se povprečno ne odrežeta boljše od pasivne in klasičnih trgovalnih strategij. Izkaže se, da SNN+m. STDP celo nekoliko preseže povprečno končno vrednost obeh LSTM ogrodij, a moramo pri tem nujno opozoriti na dejstvo, da SNN opravi veliko manj menjav kot katerokoli ogrodje z LSTM.

To pomeni, da je višja končna vrednost portfelja rezultat držanja začetnih vloženih denarnih sredstev za številne delnice (če trgovalni sistem ne trguje, ohrani popolnoma vsa začetno vložena prosta denarna sredstva, kar je dejansko bistveno več od vseh preizkušenih trgovalnih strategij), ne pa tudi ugodnih trgovalnih odločitev. Nujno bi bilo treba zasnovati kompozitni indikator uspešnosti trgovanja, ki ne bi upošteval izključno končne vrednosti portfelja, temveč tudi vmesno trgovalno aktivnost in časovno primernost trgovalnih odločitev.

Vsem trgovalnim strategijam je skupna dilema, v kolikšni meri lahko pretekla opazovanja/dogajanja/vzorci na finančni borzi prenesemo v prihodnost. Dva koraka v zmanjšanje negotovosti trgovanja sta zagotovo (1) upoštevanje dodatnih eksogenih spremenljivk globalne narave kot suplementarnih vhodnih podatkov in (2) dopolnjevanje »avtomatiziranega« učnega algoritma z »ročnimi« uporabnikovimi posredovanji. Še vedno pa je najboljši učitelj za ugotovitev prednosti in slabosti teh namigovanih delovanj v praksi, zato bi bilo najbolj smiselno prepustiti tak sistem nevidni roki trga. Če bi dejansko v praksi uporabili tovrsten sistem za trgovanje z realnimi (pravimi) denarnimi sredstvi, bi bil tak sistem glede na preference uporabnika podvržen konstantnemu izboljševanju, dokler ne bi zagotavljal pričakovanega donosa oz. bi bila v nasprotnem primeru ideja o praktičnem delovanju sčasoma opuščena.

SNN so zaenkrat najboljši približek bioloških možganov do sedaj. Ideja o prenašanju informacij preko pre- in postsinaptičnih impulzov dobro posnema delovanje nevroprenašalcev v možganih. Zaenkrat je poznavanje učenja možganov še v začetni fazi, posledično pa so rezultati preizkušanj nekoliko površni, kar opazno zmanjšuje priljubljenost teh mrež. Osebnostno sem mnenja, da uporaba nenadzorovanega učenja za nadzorovan problem ni optimalna rešitev. Kljub temu pa sem prepričan, da lahko SNN v prihodnosti pridobijo na splošni popularnosti, še posebej, če bo prišlo do preboja pri postopku učenja. Naše opravljene simulacije in-silico so pokazale, da so SNN lahko zelo uporabno orodje. Še posebej koristno si je pri sintezi učenja mrež SNN moč pomagati z optimizacijskim algoritmom, ki kot smerokaz pokaže predvideno smer konvergence, slednjega pa je moč uporabiti pri dokazovanju konvergence učenja. V tej nalogi se s konvergenco mrež SNN nismo ukvarjali, čeprav bi veljalo preizkusiti, ali za dan problem obstaja več podobno optimalnih rešitev, ali pa je rešitev problema enovita (enolična). Če je podobno dobrih rešitev več, je praktično vseeno, h kateri teži konvergenca; če je rešitev enolična, potem je treba zagotoviti konvergenco natanko v tisto smer.

Elektronski model RTC smo zgradili z namenom podrobnega spoznavanja z mrežami SNN. Sprva smo predvideli popolnoma elektronske povezave med nevroni, a smo naleteli na preštevilne težave. Zato smo se poslužili nekoliko naprednejšega pristopa – optičnih povezav med nevroni. Uporaba optike (kot optičnih ločilnikov) v analognem vezju je dobrodošla iz več razlogov: (1) omogoča analogni prenos informacij, podobno kot v bioloških možganih (amplituda, oblika, časovnost), (2) omogoča hkratni prenos informacij po enotnem kanalu različnih valovnih dolžin<sup>23</sup> (kot npr. pri fotonskem računalniku), kar pomeni, da lahko enotno vezje hkrati uporabimo za izračune več različnih zbirk podatkov, ki presenetljivo nimajo medsebojne interference, kar je velik korak k strojnemu vzporednemu računanju, (3) alternativno lahko različne valovne dolžine oddajnikov in sprejemnikov pomenijo jakost

---

<sup>23</sup> <https://lightmatter.co/story/>

signala, kar je dodatna prednost teh mrež, ki omogoča dodatno stopinjo prostosti, povrh pa se lahko ta prednost hitro in poljubno doda k obstoječi arhitekturi, (4) izhodni signali so enostavno vidni, kar izboljšuje transparentnost mreže (v primeru, da optični oddajniki oddajajo vidno svetlobo), (5) optične povezave delujejo kot napetostni ločilniki (angl. opto-coupler). Z vsemi dodatki je seveda implementacija »razširjenega« modela v računalniških simulacijah nekoliko zahtevnejša, a le do stopnje prvega nevrona in sinapse, zatem se oba lahko poljubno krat multiplicirata.

Preizkušanja RTC-SNN so se pokazala kot odlična popotnica za implementacijo kompleksnejšega simulatorja (in-silico modela). Preizkušanja RTC-SNN+m. STDP so nakazala na težavno učenje, še posebej na nezmožnost klasificiranja TP, kar nakazuje na morebiti (1) asimetričnost mreže, tj. večino primerkov pobere alternativni zunanji nevron, ali (2) prerana zaustavitev učnega postopka, ko konvergenca še poteka. Ne glede na razlog smo ugotovili, da RTC-SNN+m. STDP težko drži dolgotrajni spomin (kar je sicer bistveno odvisno od učne konstante), kar pomeni, da lahko »znanje« hitro izgubi. Pri znanju torej nikoli ne gre samo za sposobnost razširjanja ali procesiranja signalov, gre tudi za pomnjenje že naučenega; sicer se postopek učenja vedno ponavlja iz začetne točke.

Velike razlike med najnižjo in najvišjo vrednostjo memristanc terjajo visoke vrednosti učnih konstant, kar pa SNN spodbuja k hitremu pozabljanju. Dodatni problem pri tem je linearnost uporabljenega učnega algoritma m. STDP, ki predvideva linearno spreminjanje memristanc. Kljub temu vemo, da je v dejanskem vezju prisotna nelinearnost, npr. skok iz 10 k $\Omega$  na 15 k $\Omega$  ni enakomeren skoku iz 15 k $\Omega$  na 20 k $\Omega$  (to je tudi razlog, zakaj smo pri nekaterih eksperimentih spodnjo limito memristanc omejili na 7 k $\Omega$ , saj smo ugotovili, da se pod mejo 7 k $\Omega$  občutljivost vezja močno poveča). Pri mrežah SNN je kompromis med občutljivostjo in dolgoročnim spominom še posebej izrazit. Manjše odstopanje od ustaljene rutine lahko hitro nastopi kot motilni element, zato je dušenje/filtriranje učenja toliko bolj pomembno. Še posebej vhodne plasti kritično vplivajo na razširjanje vhodnega primerka proti izhodu. Vse skupaj spominja na izdelavo posebej prilagojenega postopka učenja, kot smo temu bili priča pri mrežah prve in druge generacije, a pri tem hitro naletimo na težavo. Če se po Hebbu strinjamo, da se biološki možgani fizično prilagajajo (celo plastično) odvisno od delovanja rutine s tem, da se nevroni, ki delujejo sočasno, tudi bolj povezujejo, to za nas predstavlja osnovno in enostavno vodilo učnega postopka, ki ga je treba upoštevati. Nenazadnje se živ organizem uči celo življenje, posledično pa je nesmotrno pričakovati, da bi npr. človek lahko shodil v prvih dneh življenja. Z izgradnjo kompleksnih matematičnih in iterativnih postopkov pa spet zahajamo v prakso mrež prve in druge generacije, ki se sicer poistovetijo z imenom ANN, a je matematično ozadje delovanja popolnoma nebiološko. Z zasledovanjem dejanskega razvoja mrež tretje generacije se moramo odkrito osredotočiti tudi na razvoj učnih postopkov tretje generacije. Biološko učenje (Shadmehr & Mussa-Ivaldi, 2013), kot bi ga lahko poimenovali, pa žal zajema popolnoma drugačne vidike učenja, tudi kompromis med mislimi, čustvi, nagnjenji, odraščanjem ter zavedanjem oz. nezavednim, kar je za računalniško prakso povsem nesprejemljivo.

Poleg vsega pa mreže vendarle SNN deloma vpeljujejo novo paradigmo procesiranja signalov. Pri razširjanju klasičnih večslojnih nevronskih mrežah sodelujejo vsi razpoložljivi nevroni, razen tistih, ki so izločeni s tehnikami izločevanja, npr. tehniko angl. dropout. Po Hebbovem načelu povezovanja pa se bodo zaradi močnejših povezav na eni strani in odmiranja povezav na drugi tvorili centri namenjeni za izvajanje specializiranih operacij. Tak primer v bioloških možganih

so npr. center za voh, center za sluh, center za hojo ipd. Obstaja še en izziv, saj biološki možgani kot taki nimajo točno opredeljenih vhodov, izhodov ter jasno opredeljenih plasti, kot jih mi modeliramo, pač pa so povezani mnogo globlje. Pojavita se vprašanji smiselnosti klasičnih arhitektur in vpeljava alternativnih samo-gnanih, npr. zakroženih, nevronskih arhitektur. Rezultati preizkušanj trgovanja mrež simulacij in-silico SNN+m. STDP so se izkazali kot zgledni. Primerjalna analiza metod AI je pokazala enakovrednost te metode glede na metodi LSTM, tako po parametričnem kot neparametričnem testu.

Kar je najbolj presenetljivega pri mrežah SNN (praktično vseh mrežah), je sposobnost vzporednega razširjanja signalov po posameznih nevronih in sinapsah. Ugotovitev napeljuje na implementacijo FPGA-SNN, ob predpostavki, da prostorska zahtevnost SNN ne presega zmoglosti FPGA (glede na število LUT). Morebitno širjenje/manjšanje modela FPGA-SNN sicer vpliva na prostorsko zahtevnost mreže (tudi katerekoli druge metode AI), a pri FPGA ne vpliva na časovno zahtevnost. To pomeni, da četudi povečamo prostorsko zahtevnost SNN, tj. dodamo dodatne nevrone, to ne bo vplivalo na časovno zahtevnost izvajanja algoritma SNN. Velja seveda tudi obratno, če prostorsko zahtevnost mreže zmanjšamo, to ne bi prineslo hitrejšega izvajanja. Kljub temu moramo omeniti, da smo pri implementaciji FPGA-SNN predpostavili, da so vsi zahtevani podatki FPGA-ju na voljo v njegovih spominskih registrih. Posledično to pomeni, da vseskozna komunikacija med FPGA in CPU, ki je sicer silovito hitra, ne poteka. Spomnimo, da trgovalni sistemi pridobivajo podatke preko medmrežne povezave, ki jo v danem primeru ureja CPU, ta pa jih nato mora posredovati vhodnim registrom FPGA. Ravno obratno poteka pot izhodne informacije, tj. trgovalne odločitve, iz FPGA preko vodila nazaj do CPU. Četudi izpustitev komunikacije dodobra prinese k hitrejšemu izvajanju, je pohitritev procesiranja na FPGA še vedno bistvena. Objektivno je FPGA zelo primerno namensko orodje za implementacijo »zrelega« mehankega trgovalnega sistema v končni fazi, ne pa tudi za pogosto testiranje in spreminjanje konfiguracije. Že malenkostna spremenitev konfiguracije je namreč pogojena z dolgotrajnim postopkom ponovnega prevajanja, programiranja CPU, konfiguriranja FPGA in nalaganja.

V prihodnosti bi bilo treba v trgovalne strategije vključiti tudi modele okrepitevenega učenja (angl. reinforced learning) in identifikacije anomalij (angl. anomaly detection). Glede na to, da so tržni signali (sploh pri nižjih nastavitvah spremenljivke *prag*) v manjšini, lahko potencialne nakupe in prodaje delniških instrumentov obravnavamo kot anomalije. Najbolj smiselno možnost uporabe trgovalnih strategij pa vidimo v obliki porazdeljenega sistema, znotraj katerega zaposlimo več različnih trgovalnih strategij, ki delujejo medsebojno popolnoma neodvisno. Tako lahko z večjo verjetnostjo sklepamo, npr. če nam od petih metodološko različnih trgovalnih strategij štiri poročajo, da se spleča določen instrument nemudoma prodati, bo prodaja v naslednjem kratkem časovnem oknu zares upravičena. Tako lahko dodobra znižamo pogostost trgovanja in posledično prihranimo pri transakcijskih stroških. Naj omenimo še dodatno in zelo pomembno izboljšavo za prihodnost, tj. implementacijo visoko frekventnega trgovanja na osnovi minutnih oz. celo sekundnih časovnih konstantah. Zmanjšanje časovnih konstant kliče tudi po pogostejšem preverjanju cen tečaja (angl. polling) ali celo specializiranem trgovalnem terminalu ali namenski strojni opremi.

Področje avtomatiziranega trgovanja na finančnih trgih se ukvarja s tehtanjem trgovalnih odločitev v realnem času, pri čemer sta v ospredju smiselnost in upravičenost trgovalnih odločitev. Smiselnost trgovalnih odločitev predstavlja smiselno pravilno napovedovanje gibanja tečaja, npr. rast ali upad, upravičenost, po drugi strani zagon (moment), npr. če bo

tečaj narahlo rasel en dan, nato pa bo sledila močna korekcija navzdol, menjava zelo verjetno ne bo upravičena. Smiselnosti in upravičenosti lahko pripomore sprotno izračunavanje notranje (absolutne) cene finančnega instrumenta, kar je zaradi nizke frekvence novih podatkov redkost, medtem ko so uporabljene trgovalne strategije popolnoma relativne, tj. bazirajo na tehnični analizi. V kolikor so dandanes računalniki zares odgovorni za 80 odstotkov izvedenih menjav (sumimo, da se bo odstotek v prihodnosti še povečal), se poraja vprašanje, kako naprej. Brez umetno vdane subjektivnosti gre namreč za skupek popolnoma objektivnih in strojnih odločitev, ki v tekmi za čim višji zaslužek medsebojno trgujejo drug proti drugemu. Čeprav je to dokaj umestna trditev skeptikov, pa začetni pulz še vedno obstaja v rokah ljudi. To je dokazala zadnja pandemična kriza, ki je pokazala, da sta zdravje in varnost ljudi relevanten dejavnik tudi na finančnih trgih in da se trgovalni algoritmi morajo prilagoditi situaciji in ne obratno. Vedno obstaja tudi možnost izključitve oz. zaustavitve računalnikov. Sam vidim mehanske trgovalne sisteme kot pripomoček pri sklepanju trgovalnih odločitev (kot del vsakdana) in ne kot breme, še manj kot sredstvo za masovno manipulacijo<sup>24</sup>, kar dela izziv visoko frekventnega trgovanja tako zanimivega iz ekonomskega, kakor tudi inženirskega stališča.

---

<sup>24</sup> <https://knowledge.wharton.upenn.edu/article/the-impact-of-high-frequency-trading-manipulation-distortion-or-a-better-functioning-market/>



## LITERATURA IN VIRI

- Adeli, H., & Ghosh-Dastidar, S. (2010). Improved Spiking Neural Networks with Application to EEG Classification and Epilepsy and Seizure Detection. In *Automated EEG-Based Diagnosis of Neurological Disorders* (pp. 271–304). <https://doi.org/10.1201/9781439815328-c14>
- Al-Hnaity, B., & Abbod, M. (2015). A novel hybrid ensemble model to predict FTSE100 index by combining neural network and EEMD. *2015 European Control Conference, ECC 2015*, 3021–3028. <https://doi.org/10.1109/ECC.2015.7330997>
- Almahdi, S., & Yang, S. Y. (2019). A constrained portfolio trading system using particle swarm algorithm and recurrent reinforcement learning. *Expert Systems with Applications*, *130*, 145–156. <https://doi.org/10.1016/j.eswa.2019.04.013>
- Appel, G. (2005). *Technical Analysis: Power Tools for Active Investors*. 241.
- Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques – Part II: Soft computing methods. *Expert Systems with Applications*, *36*(3), 5932–5941. <https://doi.org/10.1016/j.eswa.2008.07.006>
- Babacan, Y., Kaçar, F., & Gürkan, K. (2016). A spiking and bursting neuron circuit based on memristor. *Neurocomputing*, *203*, 86–91. <https://doi.org/10.1016/j.neucom.2016.03.060>
- Barnes, P. (2016). *Stock market efficiency, insider dealing and market abuse*. Gower.
- Bator, F. M. (1958). The Anatomy of Market Failure. *The Quarterly Journal of Economics*, *72*(3), 351. <https://doi.org/10.2307/1882231>
- Bekolay, T., Bergstra, J., Hunsberger, E., DeWolf, T., Stewart, T. C., Rasmussen, D., Choo, X., Voelker, A. R., & Eliasmith, C. (2014). Nengo: a Python tool for building large-scale functional brain models. *Frontiers in Neuroinformatics*, *7*. <https://doi.org/10.3389/fninf.2013.00048>
- Belatreche, A., Maguire, L. P., & McGinnity, M. (2007). Advances in design and application of spiking neural networks. *Soft Computing*, *11*(3), 239–248. <https://doi.org/10.1007/s00500-006-0065-7>
- Berk, J. B., & Green, R. C. (2005). Mutual Fund Flows and Performance in Rational Markets. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.383061>
- Beyeler, M., Carlson, K. D., Ting-Shuo Chou, Dutt, N., & Krichmar, J. L. (2015). CARLsim 3: A user-friendly and highly optimized library for the creation of neurobiologically detailed spiking neural networks. *2015 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2015.7280424>
- Bishop, G. W. (1961). Evolution of the Dow Theory. *Financial Analysts Journal*, *17*(5), 23–26.

<https://doi.org/10.2469/faj.v17.n5.23>

- Bitvai, Z., & Cohn, T. (2015). Day trading profit maximization with multi-task learning and technical analysis. *Machine Learning*, 101(1–3), 187–209. <https://doi.org/10.1007/s10994-014-5480-x>
- Borges, M. R. (2010). Efficient market hypothesis in European stock markets. *European Journal of Finance*, 16(7), 711–726. <https://doi.org/10.1080/1351847X.2010.495477>
- Brette, R., Rudolph, M., Carnevale, T., Hines, M., Beeman, D., Bower, J. M., Diesmann, M., Morrison, A., Goodman, P. H., Harris, F. C., Zirpe, M., Natschläger, T., Pecevski, D., Ermentrout, B., Djurfeldt, M., Lansner, A., Rochel, O., Vieville, T., Muller, E., ... Destexhe, A. (2007). Simulation of networks of spiking neurons: A review of tools and strategies. In *Journal of Computational Neuroscience* (Vol. 23, Issue 3, pp. 349–398). NIH Public Access. <https://doi.org/10.1007/s10827-007-0038-6>
- Brody, C. D., & Hopfield, J. J. (2003). Simple networks for spike-timing-based computation, with application to olfactory processing. *Neuron*, 37(5), 843–852. [https://doi.org/10.1016/S0896-6273\(03\)00120-X](https://doi.org/10.1016/S0896-6273(03)00120-X)
- Brownlee, J. (2016). Overfitting and underfitting with machine learning algorithms. *Machine Learning Mastery*.
- Cervelló-Royo, R., Guijarro, F., & Michniuk, K. (2015). Stock market trading rule based on pattern recognition and technical analysis: Forecasting the DJIA index with intraday data. *Expert Systems with Applications*, 42(14), 5963–5975. <https://doi.org/10.1016/j.eswa.2015.03.017>
- Chan, K. C., Gup, B. E., & Pan, M. S. (1997). International stock market efficiency and integration: A study of Eighteen nations. *Journal of Business Finance and Accounting*, 24(6), 803–813. <https://doi.org/10.1111/1468-5957.00134>
- Chen, S. S. (2014). Forecasting crude oil price movements with oil-sensitive stocks. *Economic Inquiry*, 52(2), 830–844. <https://doi.org/10.1111/ecin.12053>
- Cheng, J., Dong, L., & Lapata, M. (2016). Long short-term memory-networks for machine reading. *EMNLP 2016 - Conference on Empirical Methods in Natural Language Processing, Proceedings*, 551–561. <https://doi.org/10.18653/v1/d16-1053>
- Chiang, W. C., Enke, D., Wu, T., & Wang, R. (2016). An adaptive stock index trading decision support system. *Expert Systems with Applications*, 59, 195–207. <https://doi.org/10.1016/j.eswa.2016.04.025>
- Chihab, Y., Bousbaa, Z., Chihab, M., Bencharef, O., & Ziti, S. (2019). Algo-Trading Strategy for Intra-week Foreign Exchange Speculation Based on Random Forest and Probit Regression. *Applied Computational Intelligence and Soft Computing*, 2019. <https://doi.org/10.1155/2019/8342461>
- Chiu, K. C., & Xu, L. (2004). Arbitrage pricing theory-based Gaussian temporal factor analysis

- for adaptive portfolio management. *Decision Support Systems*, 37(4), 485–500. [https://doi.org/10.1016/S0167-9236\(03\)00082-4](https://doi.org/10.1016/S0167-9236(03)00082-4)
- Chong, T. T. L., & Ng, W. K. (2008). Technical analysis and the London stock exchange: Testing the MACD and RSI rules using the FT30. *Applied Economics Letters*, 15(14), 1111–1114. <https://doi.org/10.1080/13504850600993598>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*.
- Chung, Y. P. (1991). A Transactions Data Test of Stock Index Futures Market Efficiency and Index Arbitrage Profitability. *The Journal of Finance*, 46(5), 1791–1809. <https://doi.org/10.1111/j.1540-6261.1991.tb04644.x>
- Creamer, G. (2012). Model calibration and automated trading agent for Euro futures. *Quantitative Finance*, 12(4), 531–545. <https://doi.org/10.1080/14697688.2012.664921>
- Damodaran, A. (2002). Investment Valuation: 2nd Edition. In *Wiley Finance*.
- Damodaran, A. (2016). *Damodaran on valuation: security analysis for investment and corporate finance* (Vol. 324). John Wiley & Sons.
- Davison, A. P. (2008). PyNN: a common interface for neuronal network simulators. *Frontiers in Neuroinformatics*, 2. <https://doi.org/10.3389/neuro.11.011.2008>
- Day, M. Y., & Lee, C. C. (2016). Deep learning for financial sentiment analysis on finance news providers. *Proceedings of the 2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, ASONAM 2016*, 1127–1134. <https://doi.org/10.1109/ASONAM.2016.7752381>
- Dbouk, W., Jamali, I., & Soufani, K. (2014). The effectiveness of technical trading for Arab stocks. *Emerging Markets Finance and Trade*, 50(4), 5–25. <https://doi.org/10.2753/REE1540-496X500401>
- Diehl, P. U., & Cook, M. (2015). Unsupervised learning of digit recognition using spike-timing-dependent plasticity. *Frontiers in Computational Neuroscience*, 9(AUGUST), 99. <https://doi.org/10.3389/fncom.2015.00099>
- Doborjeh, M. G., Kasabov, N., & Doborjeh, Z. G. (2018). Evolving, dynamic clustering of spatio/spectro-temporal data in 3D spiking neural network models and a case study on EEG data. *Evolving Systems*, 9(3), 195–211. <https://doi.org/10.1007/s12530-017-9178-8>
- Dora, S., Subramanian, K., Suresh, S., & Sundararajan, N. (2016). Development of a Self-Regulating Evolving Spiking Neural Network for classification problem. *Neurocomputing*, 171, 1216–1229. <https://doi.org/10.1016/j.neucom.2015.07.086>
- Dreger, C., & Wolters, J. (2014). Money demand and the role of monetary indicators in forecasting euro area inflation. *International Journal of Forecasting*, 30(2), 303–312. <https://doi.org/10.1016/j.ijforecast.2013.09.008>

Dusheyko, S. (2017). *Development of spiking neural network for electromyographical signal classification*.

ECB. (2009). *Financial Stability Review, December 2009*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/financialstabilityreview200912en.pdf>

ECB. (2010). *Financial Stability Review, June 2010*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/financialstabilityreview201006en.pdf>

ECB. (2011). *Financial Stability Review, June 2011*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/financialstabilityreview201106en.pdf>

ECB. (2012). *Financial Stability Review, June 2012*.  
<https://www.ecb.europa.eu/pub/pdf/other/financialstabilityreview201206en.pdf>

ECB. (2013). *Financial Stability Review, November 2013*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/financialstabilityreview201311en.pdf>

ECB. (2014). *Financial Stability Review, May 2014. November 2013*.  
<https://www.ecb.europa.eu/pub/pdf/other/financialstabilityreview201405en.pdf>

ECB. (2015). *Financial Stability Review, November 2015*.  
<https://www.ecb.europa.eu/pub/pdf/other/financialstabilityreview201511.en.pdf>

ECB. (2016). *Financial Stability Review, November 2016*.  
<https://www.ecb.europa.eu/pub/pdf/other/financialstabilityreview201611.en.pdf>

ECB. (2017). *Financial Stability Review, May 2017*.  
<https://www.ecb.europa.eu/pub/pdf/other/ecb.financialstabilityreview201705.en.pdf>

ECB. (2018). *Financial Stability Report, May 2018*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/ecb.fsr201805.en.pdf>

ECB. (2019). *Financial Stability Review, May 2019*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/ecb.fsr201905~266e856634.en.pdf>

ECB. (2020). *Financial Stability Review, May 2020*.  
<https://www.ecb.europa.eu/pub/pdf/fsr/ecb.fsr202005~1b75555f66.en.pdf>

Edelen, R. M., Evans, R. B., & Kadlec, G. B. (2011). Scale Effects in Mutual Fund Performance: The Role of Trading Costs. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.951367>

Elias, J. G., & Rogers, W. T. (1991). An electronic artificial neuron with biologically realistic behavior. *[Proceedings] 1991 IEEE International Joint Conference on Neural Networks*, 2490–2495. <https://doi.org/10.1109/ijcnn.1991.170763>

Eppler, J. M. (2008). PyNEST: A convenient interface to the NEST simulator. *Frontiers in Neuroinformatics*, 2. <https://doi.org/10.3389/neuro.11.012.2008>

Evans, G. (2012). *Stock Market Transaction Costs and Economic Growth*.

- Fabbri, M., & Moro, G. (2018). Dow Jones Trading with Deep Learning: The Unreasonable Effectiveness of Recurrent Neural Networks. *DATA 2018 - Proceedings of the 7th International Conference on Data Science, Technology and Applications*, 142–153. <https://doi.org/10.5220/0006922101420153>
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work: Discussion. *The Journal of Finance*, 25(2), 421. <https://doi.org/10.2307/2325488>
- Fidjeland, A. K., Roesch, E. B., Shanahan, M. P., & Luk, W. (2009). NeMo: A Platform for Neural Modelling of Spiking Neurons Using GPUs. *2009 20th IEEE International Conference on Application-Specific Systems, Architectures and Processors*, 137–144. <https://doi.org/10.1109/ASAP.2009.24>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Fister, D., Fister, I., Jagrič, T., Fister, I., & Brest, J. (2019). A novel self-adaptive differential evolution for feature selection using threshold mechanism. *Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence, SSCI 2018*, 17–24. <https://doi.org/10.1109/SSCI.2018.8628715>
- Fister, D., & Jagrič, T. (2019). Online Long Short-Term Memory Network for Stock Trading. In *StuCoSReC. Proceedings of the 2019 6th Student Computer Science Research Conference* (pp. 5–8). University of Primorska Press. <https://doi.org/10.26493/978-961-7055-82-5-5-8>
- Fister, D., Mun, J. C., Jagrič, V., & Jagrič, T. (2019). Deep learning for stock market trading: A superior trading strategy? *Neural Network World*, 29(3), 151–171. <https://doi.org/10.14311/NNW.2019.29.011>
- Fister, D., Perc, M., & Jagrič, T. (2021). Two robust long short-term memory frameworks for trading stocks. *Applied Intelligence*. <https://doi.org/10.1007/s10489-021-02249-x>
- Fister, I. (2019). *Avtomatsko načrtovanje in vrednotenje klasifikacijskih cevovodov v bioinformatiki*.
- Fister, I., & Fister, I. (2021). A Brief Overview of Swarm Intelligence-Based Algorithms for Numerical Association Rule Mining. 47–59. [https://doi.org/10.1007/978-981-16-0662-5\\_3](https://doi.org/10.1007/978-981-16-0662-5_3)
- Freitas, F. D., De Souza, A. F., & de Almeida, A. R. (2009). Prediction-based portfolio optimization model using neural networks. *Neurocomputing*, 72(10–12), 2155–2170. <https://doi.org/10.1016/j.neucom.2008.08.019>
- Fujimori, T., & Watanabe, M. (2016). Full FPGA game machine. *2016 IEEE International Conference on Consumer Electronics (ICCE)*, 431–432. <https://doi.org/10.1109/ICCE.2016.7430678>

- Ghalayini, L. (2013). Modeling and Forecasting the US Dollar/Euro Exchange Rate. *International Journal of Economics and Finance*, 6(1). <https://doi.org/10.5539/ijef.v6n1p194>
- Ghosh-Dastidar, S., & Adeli, H. (2009). A new supervised learning algorithm for multiple spiking neural networks with application in epilepsy and seizure detection. *Neural Networks*, 22(10), 1419–1431. <https://doi.org/10.1016/j.neunet.2009.04.003>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Goodman, D., & Brette, R. (2008). Brian: A simulator for spiking neural networks in python. *Frontiers in Neuroinformatics*, 2(NOV), 5. <https://doi.org/10.3389/neuro.11.005.2008>
- Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 6645–6649. <https://doi.org/10.1109/ICASSP.2013.6638947>
- Grech, D., & Mazur, Z. (2004). Can one make any crash prediction in finance using the local Hurst exponent idea? *Physica A: Statistical Mechanics and Its Applications*, 336(1–2), 133–145. <https://doi.org/10.1016/j.physa.2004.01.018>
- Gupta, A., & Dhingra, B. (2012). Stock market prediction using Hidden Markov Models. *2012 Students Conference on Engineering and Systems*, 1–4. <https://doi.org/10.1109/SCES.2012.6199099>
- Hagan, M., Demuth, H., Beale, M. H., & De Jesús, O. (2014). *Neural Network Design* (2nd ed.).
- Hagströmer, B., & Binner, J. M. (2009). Stock portfolio selection with full-scale optimization and differential evolution. *Applied Financial Economics*, 19(19), 1559–1571. <https://doi.org/10.1080/09603100903018778>
- Hamid, K., Suleman, M. T., Ali Shah, S. Z., Akash, I., & Shahid, R. (2017). Testing the weak form of efficient market hypothesis: Empirical evidence from Asia-Pacific markets. *Available at SSRN 2912908*.
- Hanin, B. (2018). Which Neural Net Architectures Give Rise to Exploding and Vanishing Gradients? *ArXiv*.
- Harris, L. (2002). Trading and Exchanges. *Trading and Exchanges*, 113.
- Hazan, H., Saunders, D. J., Khan, H., Patel, D., Sanghavi, D. T., Siegelmann, H. T., & Kozma, R. (2018). BindsNET: A machine learning-oriented spiking neural networks library in python. *Frontiers in Neuroinformatics*, 12, 89. <https://doi.org/10.3389/fninf.2018.00089>
- Heath, C., Huddart, S., & Lang, M. (1999). Psychological factors and stock option exercise. *Quarterly Journal of Economics*, 114(2), 601–627. <https://doi.org/10.1162/003355399556089>
- Hochreiter, S., & Schmidhuber, J. (1997a). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

- Hochreiter, S., & Schmidhuber, J. (1997b). LSTM can solve hard long time lag problems. *Advances in Neural Information Processing Systems*, 473–479.
- Hodgkin, A. L., & Huxley, A. F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 117(4), 500–544. <https://doi.org/10.1113/jphysiol.1952.sp004764>
- Hok, L., & Zuhail, L. R. (2010). Resolving multi objective stock portfolio optimization problem using genetic algorithm. *2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE)*, 40–44. <https://doi.org/10.1109/ICCAE.2010.5451372>
- Holm, S. (1979). A Simple Sequentially Rejective Multiple Test Procedure. *Scandinavian Journal of Statistics*, 6(2), 65–70.
- Hsu, P. H., Taylor, M. P., & Wang, Z. (2016). Technical trading: Is it still beating the foreign exchange market? *Journal of International Economics*, 102, 188–208. <https://doi.org/10.1016/j.jinteco.2016.03.012>
- Huang, D., Cheng, X., Hou, T., Liu, K., & Li, C. (2019). Exploring Evaluation Factors and Framework for the Object of Automated Trading System. *Proceedings of the 52nd Hawaii International Conference on System Sciences*. <https://doi.org/10.24251/hicss.2019.152>
- Huddart, S., Lang, M., & Yetman, M. (2007). Psychological Factors, Stock Price Paths, and Trading Volume. *Working Paper, Pennsylvania State University*.
- Hunsberger, E., & Eliasmith, C. (2015). *Spiking Deep Networks with LIF Neurons*.
- Hurst, H. E. (1951). Long-Term Storage Capacity of Reservoirs. *Transactions of the American Society of Civil Engineers*, 116(1), 770–799. <https://doi.org/10.1061/taceat.0006518>
- Iakymchuk, T., Rosado-Muñoz, A., Guerrero-Martínez, J. F., Bataller-Mompeán, M., & Francés-Víllora, J. V. (2015). Simplified spiking neural network architecture and STDP learning algorithm applied to image classification. *EURASIP Journal on Image and Video Processing*, 2015(1), 4. <https://doi.org/10.1186/s13640-015-0059-4>
- Izhikevich, E. M. (2003). Simple model of spiking neurons. In *IEEE Transactions on Neural Networks* (Vol. 14, Issue 6, pp. 1569–1572). <https://doi.org/10.1109/TNN.2003.820440>
- Izhikevich, E. M. (2007). Dynamical Systems in Neuroscience. *Dynamical Systems*, 441.
- Jagrič, T., Markovič-Hribernik, T., Strašek, S., & Jagrič, V. (2010). The power of market mood - Evidence from an emerging market. *Economic Modelling*, 27(5), 959–967. <https://doi.org/10.1016/j.econmod.2010.05.005>
- Jagrič, T., Podobnik, B., & Kolanovič, M. (2005). Does the efficient market hypothesis hold? Evidence from six transition economies. *Eastern European Economics*, 43(4), 79–103. <https://doi.org/10.1080/00128775.2005.11041112>
- Jensen, M. C. (1978). Some anomalous evidence regarding market efficiency. *Journal of Financial Economics*, 6(2/3), 95–101.

- Kanazawa, Y., Asai, T., & Amemiya, Y. (2003). Basic Circuit Design of a Neural Processor: Analog CMOS Implementation of Spiking Neurons and Dynamic Synapses. *Journal of Robotics and Mechatronics*, 15(2), 208–218. <https://doi.org/10.20965/jrm.2003.p0208>
- Kasabov, N., & Capecchi, E. (2015). Spiking neural network methodology for modelling, classification and understanding of EEG spatio-temporal data measuring cognitive processes. *Information Sciences*, 294, 565–575. <https://doi.org/10.1016/j.ins.2014.06.028>
- Kasabov, N. K. (2014). NeuCube: A spiking neural network architecture for mapping, learning and understanding of spatio-temporal brain data. *Neural Networks*, 52, 62–76. <https://doi.org/10.1016/j.neunet.2014.01.006>
- Kasiński, A., & Ponulak, F. (2006). Comparison of supervised learning methods for spike time coding in spiking neural networks. In *International Journal of Applied Mathematics and Computer Science* (Vol. 16, Issue 1, pp. 101–113).
- Kay, J. (2019). *Sunshine on a Cloudy Day: Evidence in Support of a Average Strategy Across Down Markets Using ETFs*. <https://digitalcommons.library.umaine.edu/honors>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- Knauff, M., Budeck, C., Wolf, A. G., & Hamburger, K. (2010). The Illogicality of Stock-Brokers: Psychological Experiments on the Effects of Prior Knowledge and Belief Biases on Logical Reasoning in Stock Trading. *PLoS ONE*, 5(10), e13483. <https://doi.org/10.1371/journal.pone.0013483>
- Kolka, Z., Biolkova, V., Biolek, D., & Biolek, Z. (2019). Emulation of bio-inspired networks. *Advances in Science, Technology and Engineering Systems*, 4(4), 21–28. <https://doi.org/10.25046/aj040403>
- Kulkarni, S., Simon, S. P., & Sundareswaran, K. (2013). A spiking neural network (SNN) forecast engine for short-term electrical load forecasting. *Applied Soft Computing Journal*, 13(8), 3628–3635. <https://doi.org/10.1016/j.asoc.2013.04.007>
- Kwon, K. Y., & Kish, R. J. (2002). Technical trading strategies and return predictability: NYSE. *Applied Financial Economics*, 12(9), 639–653. <https://doi.org/10.1080/09603100010016139>
- Lai, K. S., & Lai, M. (1991). A cointegration test for market efficiency. *Journal of Futures Markets*, 11(5), 567–575. <https://doi.org/10.1002/fut.3990110505>
- Lee, C. C., Lee, J. De, & Lee, C. C. (2010). Stock prices and the efficient market hypothesis: Evidence from a panel stationary test with structural breaks. *Japan and the World Economy*, 22(1), 49–58. <https://doi.org/10.1016/j.japwor.2009.04.002>
- Lezhenin, I., Bogach, N., & Pyshkin, E. (2019). Urban sound classification using long short-term memory neural network. *Proceedings of the 2019 Federated Conference on Computer*



*Science and Information Systems, FedCSIS 2019*, 57–60.  
<https://doi.org/10.15439/2019F185>

- Li, D., & Qian, J. (2016). Text sentiment analysis based on long short-term memory. *2016 1st IEEE International Conference on Computer Communication and the Internet, ICCCI 2016*, 471–475. <https://doi.org/10.1109/CCI.2016.7778967>
- Li, P., Arci, F., Reilly, J., Curran, K., Belatreche, A., & Shynkevich, Y. (2017). Predicting short-term wholesale prices on the Irish single electricity market with artificial neural networks. *2017 28th Irish Signals and Systems Conference, ISSC 2017*. <https://doi.org/10.1109/ISSC.2017.7983623>
- Lillicrap, T. P., Cownden, D., Tweed, D. B., & Akerman, C. J. (2016). Random synaptic feedback weights support error backpropagation for deep learning. *Nature Communications*, 7(1), 13276. <https://doi.org/10.1038/ncomms13276>
- Linares-Barranco, B., Sánchez-Sinencio, E., Rodríguez-Vázquez, A., & Huertas, J. L. (1991). A Cmos Implementation Of Fitzhugh-Nagumo Neuron Model. *IEEE Journal of Solid-State Circuits*, 26(7), 956–965. <https://doi.org/10.1109/4.92015>
- Lintner, J. (1965). Security Prices, Risk, and Maximal Gains From Diversification. *The Journal of Finance*, 20(4), 587. <https://doi.org/10.2307/2977249>
- Lo, A. W., & MacKinlay, A. C. (2014). Stock Market Prices Do Not Follow Random Walks: Evidence from a Simple Specification Test. *A Non-Random Walk Down Wall Street*, 1(1), 17–46. <https://doi.org/10.1515/9781400829095.17>
- Lukac, L. P., Brorsen, B. W., & Irwin, S. H. (1988). A test of futures market disequilibrium using twelve different technical trading systems. *Applied Economics*, 20(5), 623–639. <https://doi.org/10.1080/00036848800000113>
- Luo, Y., Fu, Q., Xie, J., Qin, Y., Wu, G., Liu, J., Jiang, F., Cao, Y., & Ding, X. (2020). EEG-Based Emotion Classification Using Spiking Neural Networks. *IEEE Access*, 8, 46007–46016. <https://doi.org/10.1109/ACCESS.2020.2978163>
- Madura, J. (2012). *Financial institutions and markets*. South-Western.
- Malkiel, B. G. (2003). The efficient market hypothesis and its critics. *Journal of Economic Perspectives*, 17(1), 59–82. <https://doi.org/10.1257/089533003321164958>
- Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77. <https://doi.org/10.2307/2975974>
- Markowitz, H. M. (1987). Mean-Variance Analysis in Portfolio Choice and Capital Markets. In *Blackwell publishers* (Issue 2).
- Mead, D., & Stiger, P. (2015). The 2014 plunge in import petroleum prices: What happened? *Beyond the Numbers: Global Economy*, 4(9), 1–6.
- Mondal, P., Shit, L., & Goswami, S. (2014). Study of Effectiveness of Time Series Modeling

- (Arima) in Forecasting Stock Prices. *International Journal of Computer Science, Engineering and Applications*, 4(2), 13–29. <https://doi.org/10.5121/ijcsea.2014.4202>
- Murphy, J. J. (1999). Technical analysis of the financial markets: a comprehensive guide to trading methods and applications. In *New York Institute of Finance*.
- Narayan, P. K., Ahmed, H. A., & Narayan, S. (2015). Do Momentum-Based Trading Strategies Work in the Commodity Futures Markets? *Journal of Futures Markets*, 35(9), 868–891. <https://doi.org/10.1002/fut.21685>
- Neftci, E. O., Augustine, C., Paul, S., & Detorakis, G. (2017). Event-driven random back-propagation: Enabling neuromorphic deep learning machines. *Frontiers in Neuroscience*, 11(JUN). <https://doi.org/10.3389/fnins.2017.00324>
- Nelson, S. A. (1903). *The ABC of Stock Speculation*. 1–231.
- Nuntalid, N., Dhoble, K., & Kasabov, N. (2011). EEG classification with BSA spike encoding algorithm and evolving probabilistic spiking neural network. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7062 LNCS(PART 1), 451–460. [https://doi.org/10.1007/978-3-642-24955-6\\_54](https://doi.org/10.1007/978-3-642-24955-6_54)
- Olah, C. (2015). *colah's blog*.
- Painkras, E., Plana, L. A., Garside, J., Temple, S., Galluppi, F., Patterson, C., Lester, D. R., Brown, A. D., & Furber, S. B. (2013). SpiNNaker: A 1-W 18-Core System-on-Chip for Massively-Parallel Neural Network Simulation. *IEEE Journal of Solid-State Circuits*, 48(8), 1943–1953. <https://doi.org/10.1109/JSSC.2013.2259038>
- Parikh, V., & Shah, P. (2015). Stock Prediction and Automated Trading System. *International Journal of Computer Science & Communication*, July, 104–111.
- Park, J., Son, H., Lee, J., & Choi, J. (2019). Driving Assistant Companion With Voice Interface Using Long Short-Term Memory Networks. *IEEE Transactions on Industrial Informatics*, 15(1), 582–590. <https://doi.org/10.1109/TII.2018.2861739>
- Pavlidis, N. G., Tasoulis, D. K., Plagianakos, V. P., Nikiforidis, G., & Vrahatis, M. N. (2005). Spiking neural network training using evolutionary algorithms. *Proceedings of the International Joint Conference on Neural Networks*, 4, 2190–2194. <https://doi.org/10.1109/IJCNN.2005.1556240>
- Pearson, M. J., Pipe, A. G., Mitchinson, B., Gurney, K., Melhuish, C., Gilhespy, I., & Nibouche, M. (2007). Implementing spiking neural networks for real-time signal-processing and control applications: A model-validated FPGA approach. *IEEE Transactions on Neural Networks*, 18(5), 1472–1487. <https://doi.org/10.1109/TNN.2007.891203>
- Peng, L., Liu, S., Liu, R., & Wang, L. (2018). Effective long short-term memory with differential evolution algorithm for electricity price prediction. *Energy*, 162, 1301–1314. <https://doi.org/10.1016/j.energy.2018.05.052>

- Peng, Y., Choi, B., & Xu, J. (2021). Graph Learning for Combinatorial Optimization: A Survey of State-of-the-Art. *Data Science and Engineering*, 6(2), 119–141. <https://doi.org/10.1007/s41019-021-00155-3>
- Perron, P., & Phillips, P. C. B. (1988). Testing for a Unit Root in Time Series Regression. *Biometrika*, 75, 335–346.
- Pershin, Y. V., & Di Ventra, M. (2010). Experimental demonstration of associative memory with memristive neural networks. *Neural Networks*, 23(7), 881–886. <https://doi.org/10.1016/j.neunet.2010.05.001>
- Pettenuzzo, D., Timmermann, A., & Valkanov, R. (2014). Forecasting stock returns under economic constraints. *Journal of Financial Economics*, 114(3), 517–553. <https://doi.org/10.1016/j.jfineco.2014.07.015>
- Prohaska, Z. (2004). *Finančni trgi*.
- Qian, B., & Rasheed, K. (2004). Hurst exponent and financial market predictability. *Proceedings of the Second IASTED International Conference on Financial Engineering and Applications*, 203–209.
- Qu, X., Kang, X., Chao, Z., Shuai, J., & Ma, X. (2016). Short-term prediction of wind power based on deep Long Short-Term Memory. *Asia-Pacific Power and Energy Engineering Conference, APPEEC, 2016-Decem*, 1148–1152. <https://doi.org/10.1109/APPEEC.2016.7779672>
- Rao, T., & Srivastava, S. (2012). Analyzing Stock Market Movements Using Twitter Sentiment Analysis. *Proceedings of the 2012 International Conference on Advances in Social Networks Analysis and Mining*, 119–123.
- Rapach, D., & Zhou, G. (2013). Forecasting stock returns. In *Handbook of Economic Forecasting* (Vol. 2, pp. 328–383). Elsevier. <https://doi.org/10.1016/B978-0-444-53683-9.00006-2>
- Rechenberg, I. (1973). *Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Frommann-Holzboog.
- Reid, D., Hussain, A. J., & Tawfik, H. (2013). Spiking neural networks for financial data prediction. *Proceedings of the International Joint Conference on Neural Networks*. <https://doi.org/10.1109/IJCNN.2013.6707140>
- Reid, D., Hussain, A. J., & Tawfik, H. (2014). Financial time series prediction using spiking neural networks. *PLoS ONE*, 9(8), e103656. <https://doi.org/10.1371/journal.pone.0103656>
- Ross, S. A. (1976). The Arbitrage Theory of Capital Asset Pricing. *Journal of Economic Theory*, 341–360. [https://doi.org/10.1142/9789814417358\\_0001](https://doi.org/10.1142/9789814417358_0001)
- Ruiz-Cruz, R. (2018). Portfolio modeling for an algorithmic trading based on control theory. *IFAC-PapersOnLine*, 51(13), 390–395. <https://doi.org/10.1016/j.ifacol.2018.07.310>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-

- propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Ruta, D. (2014). Automated trading with machine learning on big data. *Proceedings of the 2014 IEEE International Congress on Big Data, BigData Congress 2014*, 824–830. <https://doi.org/10.1109/BigData.Congress.2014.143>
- Sak, H., Senior, A., & Beaufays, F. (2014). Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 338–342.
- Samadi, A., Lillicrap, T. P., & Tweed, D. B. (2017). Deep learning with dynamic spiking neurons and fixed feedback weights. *Neural Computation*, 29(3), 578–602. [https://doi.org/10.1162/NECO\\_a\\_00929](https://doi.org/10.1162/NECO_a_00929)
- Sarkar, S. T., Bhondekar, A. P., Macaš, M., Kumar, R., Kaur, R., Sharma, A., Gulati, A., & Kumar, A. (2015). Towards biological plausibility of electronic noses: A spiking neural network based approach for tea odour classification. *Neural Networks*, 71, 142–149. <https://doi.org/10.1016/j.neunet.2015.07.014>
- Schliebs, S., & Kasabov, N. (2013). Evolving spiking neural network—a survey. *Evolving Systems*, 4(2), 87–98. <https://doi.org/10.1007/s12530-013-9074-9>
- Sezer, O. B., & Ozbayoglu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing Journal*, 70, 525–538. <https://doi.org/10.1016/j.asoc.2018.04.024>
- Shadmehr, R., & Mussa-Ivaldi, S. (2013). Biological Learning and Control. *Biological Learning and Control*. <https://doi.org/10.7551/mitpress/9780262016964.001.0001>
- Sharpe, W. F. (1964). Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *The Journal of Finance*, 19(3), 425. <https://doi.org/10.2307/2977928>
- Shi, Y., Zheng, Y., Guo, K., & Ren, X. (2021). Stock movement prediction with sentiment analysis based on deep learning networks. *Concurrency Computation*, 33(6). <https://doi.org/10.1002/cpe.6076>
- Shiller, R. J. (2003). From efficient markets theory to behavioral finance. *Journal of Economic Perspectives*, 17(1), 83–104. <https://doi.org/10.1257/089533003321164967>
- Shin, H. W., & Sohn, S. Y. (2004). Segmentation of stock trading customers according to potential value. *Expert Systems with Applications*, 27(1), 27–33. <https://doi.org/10.1016/j.eswa.2003.12.002>
- Shynkevich, A. (2016). Predictability in bond returns using technical trading rules. *Journal of Banking and Finance*, 70, 55–69. <https://doi.org/10.1016/j.jbankfin.2016.06.010>
- Sirignano, J., & Cont, R. (2018). Universal features of price formation in financial markets: Perspectives from deep learning. *ArXiv*. <https://doi.org/10.4324/9781003145714-2>
- Šonje, V., Alajbeg, D., & Bubaš, Z. (2014). Efficient market hypothesis: is the Croatian stock

- market as (in)efficient as the U.S. market. *Financial Theory and Practice*, 35(3), 301–326. <https://doi.org/10.3326/fintp.35.3.3>
- Spoerer, C., Kietzmann, T., Mehrer, J., Charest, I., & Kriegeskorte, N. (2019). Recurrent neural networks can explain flexible trading of speed and accuracy in biological vision. *Recurrent Networks Can Recycle Neural Resources to Flexibly Trade Speed for Accuracy in Visual Recognition*, 677237. <https://doi.org/10.1101/677237>
- Storn, R., & Price, K. (1997). Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, 11(4), 341–359. <https://doi.org/10.1023/A:1008202821328>
- Strašek, S., & Jagrič, T. (2008). *Borzni trgi*. Ekonomsko-poslovna fakulteta, Inštitut za ekonomsko diagnozo in prognozo.
- Sun, G., Chen, T., Wei, Z., Sun, Y., Zang, H., & Chen, S. (2016). A carbon price forecasting model based on variational mode decomposition and spiking neural networks. *Energies*, 9(1), 54. <https://doi.org/10.3390/en9010054>
- Sutskever, I., Martens, J., & Hinton, G. (2011). Generating text with recurrent neural networks. *Proceedings of the 28th International Conference on Machine Learning, ICML 2011*, 1017–1024.
- Tan, C., Šarlija, M., & Kasabov, N. (2021). NeuroSense: Short-term emotion recognition and understanding based on spiking neural network modelling of spatio-temporal EEG patterns. *Neurocomputing*, 434, 137–148. <https://doi.org/10.1016/j.neucom.2020.12.098>
- Taylor, N. (2014). The rise and fall of technical trading rule success. *Journal of Banking and Finance*, 40(1), 286–302. <https://doi.org/10.1016/j.jbankfin.2013.12.004>
- Teixeira, L. A., & De Oliveira, A. L. I. (2010). A method for automatic stock trading combining technical analysis and nearest neighbor classification. *Expert Systems with Applications*, 37(10), 6885–6890. <https://doi.org/10.1016/j.eswa.2010.03.033>
- Toumazou, C., Georgiou, J., & Drakakis, E. M. (1998). Current-mode analogue circuit representation of Hodgkin and Huxley neuron equations. *Electronics Letters*, 34(14), 1376–1377. <https://doi.org/10.1049/el:19980989>
- Tran, K. P., Nguyen, H. Du, & Thomassey, S. (2019). Anomaly detection using Long Short Term Memory Networks and its applications in Supply Chain Management. *IFAC-PapersOnLine*, 52(13), 2408–2412. <https://doi.org/10.1016/j.ifacol.2019.11.567>
- Ullah, A., & Long, X. (2008). Risk-based portfolio strategy in emerging stock markets: economic significance from Brazil, Russia, India and China. *Macroeconomics and Finance in Emerging Market Economies*, 1(1), 31–49. <https://doi.org/10.1080/17520840701835781>
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53(8), 5929–5955. <https://doi.org/10.1007/s10462->

- Vanstone, B. J., & Finnie, G. (2007). An Empirical Methodology for Developing Stockmarket Trading Systems using Artificial Neural Networks An Emperical Methodology for Developing Stockmarket Trading Systems using Artificial Neural Networks. *School of Information Technology Information Technology Papers*.
- Vinayakumar, R., Soman, K. P., Poornachandran, P., & Sachin Kumar, S. (2018). Detecting Android malware using Long Short-term Memory (LSTM). *Journal of Intelligent and Fuzzy Systems*, 34(3), 1277–1288. <https://doi.org/10.3233/JIFS-169424>
- Vitay, J., Dinkelbach, H. Ü., & Hamker, F. H. (2015). ANNarchy: a code generation approach to neural simulations on parallel hardware. *Frontiers in Neuroinformatics*, 9. <https://doi.org/10.3389/fninf.2015.00019>
- Vrbančič, G., Brezočnik, L., Mlakar, U., Fister, D., & Fister Jr., I. (2018). NiaPy: Python microframework for building nature-inspired algorithms. *Journal of Open Source Software*, 3(23), 613. <https://doi.org/10.21105/joss.00613>
- Wade, J. J., McDaid, L. J., Santos, J. A., & Sayers, H. M. (2010). SWAT: A spiking neural network training algorithm for classification problems. *IEEE Transactions on Neural Networks*, 21(11), 1817–1830. <https://doi.org/10.1109/TNN.2010.2074212>
- Wang, F., Yu, P. L. H., & Cheung, D. W. (2014). Combining technical trading rules using parallel particle swarm optimization based on Hadoop. *Proceedings of the International Joint Conference on Neural Networks*, 3987–3994. <https://doi.org/10.1109/IJCNN.2014.6889599>
- Wang, J. Z., Wang, J. J., Zhang, Z. G., & Guo, S. P. (2011). Forecasting stock indices with back propagation neural network. *Expert Systems with Applications*, 38(11), 14346–14355. <https://doi.org/10.1016/j.eswa.2011.04.222>
- Wang, Jar-long, & Chan, S. (2009). Expert Systems with Applications Trading rule discovery in the US stock market : An empirical study. *Expert Systems With Applications*, 36(3), 5450–5455. <https://doi.org/10.1016/j.eswa.2008.06.119>
- Wang, Jie, & Wang, J. (2015). Forecasting stock market indexes using principle component analysis and stochastic time effective neural networks. *Neurocomputing*, 156, 68–78. <https://doi.org/10.1016/j.neucom.2014.12.084>
- Wang, Y. Z., Li, B., Wang, R. Q., Su, J., & Rong, X. X. (2011). Application of the Hurst exponent in ecology. *Computers and Mathematics with Applications*, 61(8), 2129–2131. <https://doi.org/10.1016/j.camwa.2010.08.095>
- Weber, B. W. (2003). Screen-based trading in futures markets: recent developments and research propositions. *leexplore.lee.org*, 10. <https://doi.org/10.1109/hicss.1999.772767>
- Wilder, J. (1978). New Concepts in Technical Trading Systems. *New Concepts in Technical*

*Trading Systems*, 24(3), 63–69.

- Wilson, C. L. (1994). Self-organizing neural network system for trading common stocks. *IEEE International Conference on Neural Networks - Conference Proceedings*, 6, 3651–3654. <https://doi.org/10.1109/icnn.1994.374924>
- Wong, W. K., Manzur, M., & Chew, B. K. (2003). How rewarding is technical analysis? Evidence from Singapore stock market. *Applied Financial Economics*, 13(7), 543–551. <https://doi.org/10.1080/0960310022000020906>
- Xin, J., & Embrechts, M. J. (2001). Supervised learning with spiking neural networks. *Proceedings of the International Joint Conference on Neural Networks*, 3, 1772–1777.
- Yavuz, E., Turner, J., & Nowotny, T. (2016). GeNN: a code generation framework for accelerated brain simulations. *Scientific Reports*, 6(1), 18854. <https://doi.org/10.1038/srep18854>
- Zaytar, M. A., & Amrani, C. El. (2016). Sequence to Sequence Weather Forecasting with Long Short-Term Memory Recurrent Neural Networks. *International Journal of Computer Applications*, 143(11), 975–8887.
- Zen, H., & Sak, H. (2015). Unidirectional long short-term memory recurrent neural network with recurrent output layer for low-latency speech synthesis. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, 2015-August*, 4470–4474. <https://doi.org/10.1109/ICASSP.2015.7178816>
- Zheng, S., Ristovski, K., Farahat, A., & Gupta, C. (2017). Long Short-Term Memory Network for Remaining Useful Life estimation. *2017 IEEE International Conference on Prognostics and Health Management, ICPHM 2017*, 88–95. <https://doi.org/10.1109/ICPHM.2017.7998311>
- Zhou, Y., Wang, W., & Huang, X. (2015). FPGA Design for PCANet Deep Learning Network. *2015 IEEE 23rd Annual International Symposium on Field-Programmable Custom Computing Machines*, 232–232. <https://doi.org/10.1109/FCCM.2015.45>
- Zhu, X., Sobhani, P., & Guo, H. (2016). DAG-structured long short-term memory for semantic compositionality. *2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL HLT 2016 - Proceedings of the Conference*, 917–926. <https://doi.org/10.18653/v1/n16-1106>





# PRILOGE

<i>Priloga 1: Utemeljitev izvirnosti teme</i>	2
<i>Priloga 2: Delovni življenjepis kandidata</i>	3
<i>Priloga 3: Izjava o avtorstvu in istovetnosti tiskane in elektronske oblike disertacije</i>	4

### Priloga 1: Utemeljitev izvirnosti teme

Informacije o opravljenih poizvedbah v spodnji tabeli pričajo o relevantnosti ključnih besed »deep learning« in »long short-term memory networks«, saj slednji prinašata obilo zadetkov. Z vpeljavo ključne besede »mechanical trading system« se nabor izrazito zmanjša, kar nakazuje na slabo raziskanost tovrstne teme. Relevantni sta tudi ključni besedi »efficient market hypothesis« in »european stock market«.

Kombinacija ključnih besed »long short term memory« in »mechanical trading system« prinese le 1 zadek v WoS, medtem ko kombinacija vseh ključnih besed »deep learning«, »long short-term memory«, »mechanical trading system«, »efficient market hypothesis« in »european stock market« nobenega. S tem izkazujemo izvirnost predlagane teme.

Tabela 1: Informacija o opravljenih poizvedbah (v bazah doktorskih disertacij, bazah patentov ter ustreznih primarnih in sekundarnih bazah znanstvenih objav), poizvedbe v WoS so obvezne

	<b>D&amp;T</b>	<b>WoS</b>
<b>deep learning and long short-term memory networks</b>	62	
<b>deep learning and long short-term memory networks and trading system</b>		5
<b>deep learning and mechanical trading system</b>	1	1
<b>deep learning and efficient market hypothesis</b>	2	3
<b>efficient market hypothesis and european stock market</b>	13	52
<b>long short-term memory and efficient market hypothesis and european stock market</b>	0	1
<b>long short term memory and mechanical trading system</b>	0	1
<b>deep learning and long short-term memory and mechanical trading system and efficient market hypothesis and european stock market</b>	0	0

## Priloga 2: Delovni življenjepis kandidata

dusan@dusanfister.com

<http://dusanfister.com/>

<https://orcid.org/0000-0002-9604-0554>

<https://www.researchgate.net/profile/Dusan-Fister/>

<https://publons.com/researcher/1299423/dusan-fister/>

<https://scholar.google.com/citations?user=HQ5hY3kAAAAJ&hl=sl&oi=ao>

### Izobrazba:

- 2000 – 2008 Osnovna šola Bakovci
- 2008 – 2012 Srednja šola Gimnazija Franca Miklošiča Ljutomer
- 2012 – 2015 Dodiplomski študij Mehatronika, UM FS
- 2015 – 2017 Magistrski študij Mehatronika, UM FS
- 2018 Certificiran iz obvladovanja kvantitativnih tveganj (CQRM), IIPER, OSL House
- 2020 -> Študent programa prometnega pilota (ATPL), AAT Gradec (Avstrija)

### Delovne izkušnje:

- 10. 2. 2022 -> Raziskovalni sodelavec, Universidad Alcalá de Henares (Španija)
- 2. 10. 2017 – 31. 1. 2022 Mladi raziskovalec, UM EPF
- 1. 10. 2020 – 31. 1. 2022 Asistent za predmetni področji Ekonomija in aplikativna ekonometrija ter Finance
- 1. 1. 2018 – 31. 1. 2022 Delovni sodelavec in svetovalec Svetovne zdravstvene organizacije (WHO)
- 3. 10. 2016 – 1. 3. 2017 Demonstrator, UM FERI
- 4. 04. 2016 – 30.09. 2016 Delovni sodelavec Laboratorija za oljno hidravliko, UM FS
- 1. 09. 2014 – 29. 9. 2017 Delovni sodelavec Alma Mater Europea
- 6. 10. 2014 – 1. 3. 2017 Študent raziskovalec na dveh projektih PKP, UL FGG

### Nagrade:

- 2019 Nagrada najboljšega prispevka na študentski konferenci ICSI
- 2018 Perlachova nagrada za tehnične študije UM
- 2017 Tretji najboljši študent UM
- 2017 Nagrada za najboljše pomursko magistrsko nalogo, PAZU, PIF
- 2016 Plaketa Leona Štuklja za športne dosežke UM
- 2016 Priznanje FERI za najboljše raziskovalne dosežke študentov
- 2010 – 2016 Prejemnik Zoisove štipendije

### Zanimanja:

- Večkratni udeleženec programa mobilnosti ERASMUS+ za zaposlene
- Navdušen športnik, kolesar, tekač, triatlonec, nominiran za najboljšega športnika Pomurja 2015
- Zagovornik računalniške varnosti in zasebnosti

Priloga 3: Izjava o avtorstvu in istovetnosti tiskane in elektronske oblike disertacije

**UNIVERZA V MARIBORU**

EKONOMSKO-POSLOVNA FAKULTETA

Izjava o avtorstvu in istovetnosti tiskane in elektronske oblike disertacije

Ime in priimek študenta/-ke: Dušan Fister

Študijski program: Ekonomске in poslovne vede

Naslov doktorske disertacije: Uporaba umetne inteligence pri upravljanju portfelja delnic

Mentor/-ica: red. prof. ddr. Timotej Jagrič, CQRM

Somentor/-ica: red. prof. dr. Matjaž Perc

Podpisani/-a študent/-ka: Dušan Fister

- izjavljam, da je zaključno delo rezultat mojega znanstvenoraziskovalnega dela;
- izjavljam, da sem pridobil/-a vsa potrebna soglasja za uporabo podatkov in avtorskih del v zaključnem delu in jih v zaključnem delu jasno in ustrezno označil/-a;
- na Univerzo v Mariboru neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve avtorskega dela v elektronski obliki, pravico reproduciranja ter pravico ponuditi zaključno delo javnosti na svetovnem spletu preko DKUM in drugih informacijskih zbirk in ponudnikov; sem seznanjen/-a, da bodo dela deponirana/objavljena v DKUM dostopna široki javnosti pod pogoji licence Creative Commons BY-NC-D, kar vključuje tudi avtomatizirano indeksiranje preko spleta in obdelavo besedil za potrebe tekstovnega in podatkovnega rudarjenja in ekstrakcije znanja iz vsebin; uporabnikom se dovoli reproduciranje brez predelave avtorskega dela, distribuiranje, dajanje v najem in priobčitev javnosti samega izvirnega avtorskega dela, in sicer pod pogojem, da navedejo avtorja in da ne gre za komercialno uporabo;
- dovoljujem objavo svojih osebnih podatkov, ki so navedeni v zaključnem delu in tej izjavi, skupaj z objavo zaključnega dela;
- izjavljam, da je tiskana oblika zaključnega dela istovetna elektronski obliki zaključnega dela, ki sem jo oddal/-a za objavo v DKUM;
- Izjavljam, da sem seznanjen s pogoji Proquest-a za oddajo in javno objavo doktorske disertacije v podatkovno zbirko ProQuest Dissertations & Theses Global (<http://contentz.mkt5049.com/lp/43888/382619/PQDTauthoragreement.pdf>).

Kraj in datum: Alcalá de Henares, 29. Mar. 2022

Podpis študenta/-ke: Dušan Fister