



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

## ÚSTAV INFORMATIKY

INSTITUTE OF INFORMATICS

# VYUŽITÍ UMĚLÉ INTELIGENCE JAKO PODPORY PRO ROZHODOVÁNÍ V PODNIKU

THE USE OF ARTIFICIAL INTELLIGENCE FOR DECISION MAKING IN THE FIRM

## DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. MILOŠ VOLNÝ

### VEDOUCÍ PRÁCE

SUPERVISOR

prof. Ing. PETR DOSTÁL, CSc.

BRNO 2019

# Zadání diplomové práce

Ústav: Ústav informatiky  
Student: **Bc. Miloš Volný**  
Studijní program: Systémové inženýrství a informatika  
Studijní obor: Informační management  
Vedoucí práce: **prof. Ing. Petr Dostál, CSc.**  
Akademický rok: 2018/19

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává diplomovou práci s názvem:

## **Využití umělé inteligence jako podpory pro rozhodování v podniku**

### **Charakteristika problematiky úkolu:**

Úvod  
Vymezení problému a cíle práce  
Teoretická východiska práce  
Analýza problému a současné situace  
Vlastní návrhy řešení, přínos návrhů řešení  
Závěr  
Seznam použité literatury  
Přílohy

### **Cíle, kterých má být dosaženo:**

Vymezení řešeného problému a stanovení celkového a dílčích cílů. Provedení teoretického popisu základů použité teorie prostředků umělé inteligence, popis a analýza problému, vyhodnocení současné situace, provedení návrhu řešení a zhodnocení přínosu návrhu řešení.

### **Základní literární prameny:**

DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: CERM, 2011. 168 s. ISBN 978-80-7204-747-5.

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: CERM, 2012. 718 s. ISBN 978-80-7204-798-7.

HANSELMAN, D. a B. LITTLEFIELD. Mastering MATLAB. Pearson Education International Ltd., 2012. 852 s. ISBN 978-0-13-185714-2.

MAŘÍK, V., O. ŠTĚPÁNKOVÁ a J. LAŽANSKÝ. Umělá inteligence. Praha: ACADEMIA, 2013. 2473 s.  
ISBN 978-80-200-2276-9.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2018/19

V Brně dne 28.2.2019

L. S.

---

doc. RNDr. Bedřich Půža, CSc.  
ředitel

---

doc. Ing. et Ing. Stanislav Škapa, Ph.D.  
děkan

## **Abstrakt**

Táto práca sa zaoberá problematikou predikcie vývoja trendu na kapitálových trhoch pomocou neurónových sietí. V práci je diskutované využitie konvolučných a rekurentných neurónových sietí, Elliottovej vlnovej teórie a scalogramov na predikciu vývoja trendu na kapitálových trhoch. Cieľom práce je návrh systému založeného novom prístupe k predikcii vývoja trendu na kapitálových trhoch pomocou Elliottovej vlnovej teórie. Jadro systému bude tvoriť konvolučná neurónová sieť detekujúca zvolené vzory Elliottovej teórie ich rozpoznávaním zo scalogramov získaných spojitou vlnkovou transformáciou častí historických časových rád vybraných kurzov akcií.

## **Summary**

This thesis is concerned with future trend prediction on capital markets on the basis of neural networks. Usage of convolutional and recurrent neural networks, Elliott wave theory and scalograms for capital market's future trend prediction is discussed. The aim of this thesis is to propose a novel approach to future trend prediction based on Elliott's wave theory. The proposed approach will be based on the principle of classification of chosen patterns from Elliott's theory by the way of convolutional neural network. To this end scalograms of the chosen Elliott patterns will be created through application of continuous wavelet transform on parts of historical time series of price for chosen stocks.

## **Klíčová slova**

scalogram, kapitálové trhy, Elliottova vlnová teória, neurónové siete, CNN, LSTM, klasifikácia, predikcia

## **Keywords**

scalogram, capital markets, Elliott wave theory, neural networks, CNN, LSTM, classification, prediction

VOLNÝ, Miloš. *Využití umělé inteligence jako podpory pro rozhodování v podniku* [online]. Brno, 2019 [cit. 2019-05-12]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/119959>. Diplomová práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav informatiky. Vedoucí práce Petr Dostál.

Prehlasujem, že som túto diplomovú prácu vypracoval samostatne pod vedením prof. Ing. Petra Dostála, CSc. a uviedol som všetky literárne pramene a publikácie, z ktorých som čerpal.

Bc. Miloš Volný



Chcel by som poďakovať vedúcemu mojej diplomovej práce prof. Ing. Petrovi Dostálovi, CSc. za jeho ochotu, mnohé rady a cenné postrehy. Taktiež by som rád poďakoval doc. Eve Volnej z Ostravskej Univerzity za jej ochotu diskutovať jej prácu v oblasti rozpoznávania Elliotových vln.

Bc. Miloš Volný

# Obsah

<b>1</b>	<b>Úvod</b>	<b>3</b>
<b>2</b>	<b>Vymedzenie problému a ciele práce</b>	<b>4</b>
<b>3</b>	<b>Finančný manažment podniku a investičné stratégie</b>	<b>5</b>
3.1	Typy investičných stratégií . . . . .	5
3.2	Investičné riziká . . . . .	6
3.3	Analýza rizika investičných projektov . . . . .	7
3.4	Kritéria hodnotenia efektívnosti investícií . . . . .	8
<b>4</b>	<b>Neuronové siete</b>	<b>10</b>
4.1	Princíp fungovania neurónových sietí . . . . .	10
4.2	Východisko . . . . .	10
4.3	Typy neurónových sietí . . . . .	14
4.4	Vybrané typy neurónových sietí . . . . .	17
<b>5</b>	<b>Akciové analýzy</b>	<b>21</b>
5.1	Fundamentálna analýza . . . . .	21
5.2	Psychologická analýza . . . . .	21
5.3	Technická analýza . . . . .	21
5.4	Grafické metódy . . . . .	22
5.5	Indikátory technickej analýzy . . . . .	22
<b>6</b>	<b>Elliottova vlnová teória</b>	<b>26</b>
6.1	Základy teórie . . . . .	26
6.2	Hybné vlny . . . . .	26
6.3	Korekčné vlny . . . . .	27
<b>7</b>	<b>Analýza časových rád</b>	<b>28</b>
7.1	Spojité vlnková transformácia . . . . .	28
7.2	Hurstov exponent . . . . .	29
<b>8</b>	<b>Zhrnutie teoretického východiska</b>	<b>30</b>
<b>9</b>	<b>Prehľad využitia umelej inteligencie na kapitálových trhoch</b>	<b>31</b>
<b>10</b>	<b>Implementácia</b>	<b>32</b>
10.1	Konvolučná neurónová sieť na princípe Elliottovej teórie . . . . .	32
10.2	Sieť typu Long Short Term Memory . . . . .	46
<b>11</b>	<b>Testovanie</b>	<b>50</b>
11.1	Metodológia testovania . . . . .	50
11.2	Testovacie dáta . . . . .	51
11.3	Testovanie . . . . .	52



<b>12 Zhodnotenie</b>	<b>75</b>
12.1 Ekonomický prínos . . . . .	77
12.2 Ďalšie smerovanie práce . . . . .	78
<b>13 Záver</b>	<b>79</b>

# 1. Úvod

Umelá inteligencia je jedným z najvýznamnejších technologických trendov súčasnosti, zaradovaná spoločnosťami ako Accenture [1] a Gartner [15] medzi trendy s najväčším dopadom na budúcnosť podnikania. Adopcia umelej inteligencie sa stáva pre firmy čoraz dôležitejšiou a lacnejšou, a tak viac preniká do podnikovej praxe aj stredných a menších podnikov. V kontexte riadenia podniku je finančný manažment veľmi významnou súčasťou rozhodovania, a investičné stratégie podniku zohrávajú v jeho úspechu kľúčovú úlohu. Pomerne bežnou stratégiou je investovanie malej časti čistého zisku na kapitálových a akciových trhoch s cieľom tieto prostriedky zhodnotiť a tak zvýšiť hodnotu svojho podniku. Strojové učenie, a konkrétne neurónové siete, majú preukázaný potenciál úspešne predikovať vývoj kurzov na kapitálových trhoch, ale sú zväčša používané maklérmi na informovanie ich obchodnej stratégie. Cieľom tejto práce je implementovať a natréňovať neurónovú sieť za účelom obchodovania na akciových trhoch, a následne zhodnotiť, či by mohlo ísť o zaujímavú alternatívu investičnej stratégie z pohľadu finančného manažmentu podniku.

Kapitoly tejto práce najprv poskytnú prehľad o teoretickom východisku z tém investičného rozhodovania, teórie neurónových sietí a technickej analýzy na akciových trhoch. V neskorších kapitolách popíšeme architektúru navrhnutých neurónových sietí, vyhodnotíme ich úspešnosť, a nakoniec vyhodnotíme potenciál prístupu obchodovania založenom na neurónovej sieti v podnikovej praxi.

## 2. Vymedzenie problému a ciele práce

Táto práca sa zaoberá problematikou využitia strojového učenia, konkrétne deep learningu pomocou neurónových sietí, pre predikciu vývoja trendu akcie na akciových trhoch s cieľom realizácie kapitálového zisku. Záujem práce sa sústreďuje na konvolučnú neurónovú sieť, často používanú na rozpoznávanie obrazu a rekurentnú sieť typu Long-Short Term Memory, vhodnú na analýzu časových rád.

Cieľom tejto práce je návrh a implementácia nového prístupu k predikcii trendu kurzov akcií na kapitálovom trhu. Tento nový prístup bude využívať konvolučnú neurónovú sieť s cieľom rozpoznávať scalogramy vybraných vzorov vln Elliottovej vlnovej teórie, ktorá popisuje správanie investorov na kapitálovom trhu. Pre zhodnotenie tohto prístupu sa využije sieť typu Long-Short Term Memory, taktiež navrhnutá v priebehu tejto práce. Po implementácii sietí oboch typov prebehne zhodnotenie efektívnosti novo navrhnutého prístupu. Sieť typu Long Short Term Memory bude tréňovaná na historických dáta kurzu akcie a jej ukazovateľov technickej analýzy. Pri konvolučnej neurónovej sieti je zámerom tejto práce na tréning využiť princíp rozpoznávania impluzov a korekcií Elliottovej vlnovej teórie z grafov vývoja hodnoty kurzu vybranej akcie. Implementácia prebehne v programovacom jazyku Python. Efektívnosť sietí bude zhodnotená na základe ich kapitálového zisku v simulovanom obchodovaní na kapitálovom trhu ich vzájomným porovnaním.

# 3. Finančný manažment podniku a investičné stratégie

V tejto kapitole v krátkosti predstavíme stratégie a faktory vplývajúce na investície podniku, ako aj spôsoby ich hodnotenia. Investičná stratégia je súčasťou celkovej finančnej stratégie podniku a zaoberá sa rozhodovaním o investovaní do dlhodobého majetku podniku. Všeobecne rieši koľko a kedy má podnik celkovo investovať, ako aj do akého typu dlhodobého majetku alebo investičného projektu by táto investícia mala ísť. Základom investičnej stratégie a strategického investičného rozhodovania je stanovenie kritérií, ktoré slúžia na posudzovanie jednotlivých investičných variant. Za základné investičné kritérium môžeme považovať **kritérium čistej súčasnej hodnoty Net Present Value - NPV**. Hodnota majetku vlastníkov podniku sa zvyšuje, iba ak je NPV investície kladné. To sa dá dosiahnuť v prípade, že je diskontovaný príjem z investície vyšší ako s ňou spojené výdaje.

Ďalej môžeme každú investíciu posúdiť z pohľadu tzv. investičného trojuholníku:

- očakávaný výnos investície - prírastok k doposiaľ nazhromaždeným výnosom
- riziko - očakávané riziko investície
- likvidita - predpokladaný dopad investície na likviditu podniku, alebo aj schopnosť premeniť investíciu v hotovosť

## 3.1. Typy investičných stratégií

Podľa preferencií faktorov investičného trojuholníku môže investor zvoliť rôzne typy investičných stratégií zameraných na maximálny ročný výnos, maximálnu likviditu alebo minimálne riziko. V tejto podsekcii krátko predstavíme niekoľko typov stratégií podľa [17].

**Maximalizácia ročných výnosov** Táto stratégia sa volí pri nižšom stupni inflácie a jej podstatou je investícia, ktorá si udržuje svoju reálnu hodnotu a sú s ňou spojené pravidelné ročné výnosy.

**Rast ceny investície** Pri tejto stratégii sú nižšie ročné výnosy kompenzované predpokladaným nárastom hodnoty investície v budúcnosti - tzv. kapitálový zisk. Tento typ stratégie je vhodný pri vyššom stupni inflácie, ktorá znižuje atraktivnosť bežných ročných výnosov.

**Rast ceny investície spojená s maximálnymi ročnými výnosmi** Ideálna stratégia, ktorej cieľom je vybrať investičné projekty, ktoré budú mať vysoké ročné výnosy, ako aj kapitálový zisk. V praxi veľmi ťažko realizovateľné.

**Agresívna investičná stratégia** Stratégia, kde investor preferuje projekty s vysokým stupňom rizika, ktoré je kompenzované vysokým očakávaným výnosom.

**Konzervatívna stratégia** Tu investor naopak preferuje projekty bezrizikové, alebo len s nízkym rizikom. Investor pri implementácii tohto typu stratégie často minimalizuje riziko vytváraním investičného portfólia.

**Stratégia maximálnej likvidity** Pri stratégii maximálnej likvidity volí investor projekty s najvyššou schopnosťou premeniť investované čiastky na peňažnú hotovosť. Táto stratégia je vhodná pre podniky, ktoré nemajú zabezpečenú dlhodobú platobnú schopnosť alebo pri prudkej zmene inflácie a následnom upravení investičnej stratégie.

## 3.2. Investičné riziká

Pri podnikaní existuje nebezpečenstvo, že dosiahnuté výsledky v podnikaní sa budú líšiť od pôvodného odhadu. Tento jav nazývame rizikom, a pre úspešné zvládnutie investičných projektov je ho nutné zohľadniť. [17] člení druhy rizika nasledovne:

### 1. Podľa závislosti na podnikovej činnosti

- Riziko objektívne je nezávislé od činnosti podniku, vôle a schopností vlastníkov, managementu a zamestnancov
- Riziko subjektívne je závislé od činnosti podniku (napr. nedostatočné technické, ekonomické, a iné znalosti)
- Riziko kombinované má prvky objektívne aj subjektívne

### 2. Podľa jednotlivých činností podniku

- Riziko prevádzkové - štrajk, havária, úraz, ...
- Riziko trhové - odbyt, cena, kurz
- Riziko inovačné - alokácia peňazí do majetku
- Riziko finančné - zadlženie, insolvencia, ...
- Celkové podnikateľské riziko plynúce z podnikania - prejavuje sa v hodnote firmy, jej akcií, v dividendách, atď.

### 3. Podľa závislosti na vývoji celkovej ekonómie alebo v jednotlivjej firme

- Riziko systematické vzniká kvôli celkovému ekonomickému vývoju
- Riziko jedinečné je unikátne pre daný obor, podnik, projekt, a pod.

Ochranu proti riziku podnik volí na základe svojho postoju k nemu. Rozlišujeme tri základné postoje

- averzia k riziku - podnik sa snaží vyhýbať riskantným projektom
- sklon k riziku - podnik vyhľadáva riskantnejšie projekty v snahe vyššieho zisku
- neutrálny postoj k riziku

Samotná ochrana proti riziku sa potom uskutočňuje jedným z dvoch spôsobov - elimináciou rizika (odstránením príčin jeho vzniku) alebo redukciou nepriaznivých dopadov rizika na prijateľnú mieru. Redukcia nepriaznivých dopadov je obvyklejším prístupom a využíva spôsoby znižovania rizika ako napríklad:

- voľba právnej formy podnikania
- stanovením rizikových medzí pre jednotlivé prípady (zadlženosť, pokles ceny, atď.)
- diverzifikácia rizika (vertikálna, horizontálna, geografická, a iné)
- delením rizika na niekoľko účastníkov
- poistením (v prípade poistiteľných rizík)
- presunom rizika na iné subjekty (leasing, zmluvné ceny, termínované obchody)

### 3.3. Analýza rizika investičných projektov

Z hľadiska investícií musíme zohľadniť riziká vplývajúce na ich výnosnosť, teda hlavne **riziko zmeny predpokladanej výnosnosti**. Pri investovaní teda ako kompenzáciu za podstúpenie tohto rizika a za odloženie spotreby (viazanie prostriedkov) investor požaduje určitú úroveň výnosnosti - tzv. **požadovanú výnosnosť**. Investícia je prijateľná ak platí očakávaná výnosnosť  $\geq$  požadovaná výnosnosť.

**Požadovanú výnosnosť** delíme z hľadiska rizika na dve zložky:

- bezriziková výnosnosť je výsledkom reálnej výnosnosti z bezrizikovej investície (napr. štátne obligácie) a miery inflácie, ktorá vedie na vyššie požiadavky bezrizikovej výnosnosti
- riziková prémie je napr. premiou za likviditu, riziko spojené s oborom podnikania, za nesplatenie dlhu, za finančné riziko plynúce z finančnej štruktúry podniku.

Vo všeobecnosti môžeme povedať, že medzi výškou rizika a výškou požadovanej výnosnosti je priama úmernosť.

Stupeň rizika môžeme vyjadriť matematicky pomocou **smerodajnej odchýlky** od priemernej očakávanej hodnoty a tzv. **variačného koeficientu**.

**Smerodajná odchýlka** príjmov investičného projektu priamo napovedá o jeho riziku, čím vyššia odchýlka, tým je projekt riskantnejší. Matematicky je definovaná ako:

$$\sigma = \sqrt{\sum_{j=1}^N (P_j - PP)^2 v_j} \quad (3.1)$$

Smerodatná odchýlka má však dobrú výpovednú hodnotu iba pre projekty s približne rovnakou očakávanou priemernou hodnotou. Pre ostatné prípady je vhodnejšie použiť **variančný koeficient**, ktorý je pomerom smerodajnej odchýlky a priemernej očakávanej hodnote príjmov z investície.

$$Var = \frac{\sigma}{PP} \quad (3.2)$$

$PP$  je priemerný očakávaný príjem z investície.

### 3.3.1. Premietanie rizika do finančných kritérií posudzovania efektivity investícií

Túto kvantifikáciu rizika premietame do finančných kritérií buď upravením diskontnej sadzby - čím vyššie riziko tým vyššiu zvolíme úrokovú sadzbu pre výpočet čistej súčasnej hodnoty, alebo stanovením rizikových tried, v rámci ktorých zase upravíme diskontnú sadzbu

## 3.4. Kritéria hodnotenia efektívnosti investícií

[17] predstavuje niekoľko finančných kritérií a metód hodnotenia, avšak pre potreby tejto práce sa budeme zaoberať iba vybranými metódami, jednou založenou na ziskových kritériách a metódami založenými na kritériách peňažných tokov.

### 3.4.1. Metódy založené na ziskových kritériách

Tieto metódy hodnotenia počítajú s účtovným ziskom zníženým o daň z príjmu, pričom neuvažujú odpisy a prípadné ďalšie peňažné príjmy súvisiace s investíciou.

#### Doba návratnosti investičného projektu

$$DN = \frac{KV}{Z_r} \quad (3.3)$$

Kde  $DN$  je doba návratnosti,  $Z_r$  je priemerný ročný zisk z investície a  $KV$  sú kapitálové výdaje.

Nevýhodou tejto metódy je to, že nepočíta s časovou hodnotou peňazí, to môžeme eliminovať použitím diskontovaných peňažných tokov. Za ďalší nedostatok môžeme považovať fakt, že metóda neposkytuje informácie o výnosnosti projektu po jeho dobe splatnosti a o jeho príspevku k trhovej hodnote podniku.

### 3.4.2. Metódy založené na peňažných tokoch

Tieto metódy sú podľa finančnej teórie najvhodnejšie, nakoľko zohľadňujú všetky príjmy aj výdaje súvisiace s investíciou. Všetky tieto metódy vychádzajú z výpočtu čistej súčasnej hodnoty.

**Čistá súčasná hodnota** Čistá súčasná hodnota (NPV) je rozdielom diskontovaných peňažných príjmov z investície a na nich vynaložených kapitálových výdajov, ktoré môžu tiež byť diskontované, ak bol investičný projekt realizovaný niekoľko rokov. NPV vypočítame ako:

$$NPV = \sum_{t=1}^N \frac{CF_t}{(1+i)^t} \quad (3.4)$$

kde  $N$  je doba životnosti investície,  $t$  sú jednotlivé roky životnosti,  $i$  je diskontná sadzba a  $CF_t$  je peňažný tok z investície v jednotlivých rokoch jej životnosti.

Ukazovateľ NPV vyjadruje efekt, ktorý investícia spôsobí nad rámec nami požadovanej

výnosnosti a teda bude zvyšovať trhovú hodnotu podniku. Z toho plynie aj rozhodovanie o prijateľnosti investície na základe NPV. Ak  $NPV \geq 0$ , tak je investičný projekt prijateľný, nakoľko dosiahne aspoň požadovanú výnosnosť. NPV môžeme použiť aj na výber optimálnej varianty, kde variant s najvyšším NPV bude z pohľadu výnosovej miery najlepší.

**Index rentability** Index rentability (PI) je pomerovým ukazovateľom, ktorý charakterizuje výnosnosť investície. O prijateľnú investíciu sa jedná, ak  $PI > 1$ . V [17] sa odporúča PI používať vtedy, ak podnik nemá dost prostriedkov na financovanie všetkých investičných projektov s nezáporným NPV a chce vybrať tie s najvyšším zhodnotením. Index rentability vypočítame nasledovne:

$$PI = \frac{\sum_{t=1}^N \frac{P_t}{(1+i)^t}}{KV} \quad (3.5)$$

Kde  $N, i, t$  sú doba životnosti, diskontná sadzba, jednotlivé roky životnosti projektu, a  $KV, P_t$  sú kapitálové výdaje a príjem investície za daný rok.



## 4. Neuronové siete

Umelá inteligencia momentálne zažíva bezprecedentný nárast adopcie do podnikovej praxe v podobe rozpoznávania hlasu alebo obrazu, vo forme chatovacích robotov, ale aj v podpore analýz a rozhodovania. Jednou z jej najzaujímavejších a najrýchlejšie rastúcich disciplín sú neuronové siete, ktoré sú jadrom aj tejto práce. Táto kapitola poskytne prehľad o všeobecnom princípe fungovania neuronových sietí, a priblíži dva typy sietí, konvolučné a rekurentné, ktorými sa budeme zaoberať bližšie. Kapitola čerpá z [4] a [12].

### 4.1. Princíp fungovania neuronových sietí

Neuronové siete napodobňujú fungovanie ľudského mozgu. Zvyčajne sa používajú na modelovanie veľmi komplexných procesov, kde nie je možné jednotlivé závislosti medzi dátami modelovať iným, ľahším spôsobom. Z toho však vychádza aj jeden z problémov použitia neuronových sietí - ich funkcia ako tzv. "čiernej skrinky" - pri rozhodnutiach, prípadne predikciách získaných neuronovou sieťou je takmer nemožné vysvetliť proces, ktorým sieť k danému záveru prišla.


### 4.2. Východisko

Ako bolo spomenuté, neuronové siete sú aproximáciou ľudského mozgu a sú teda založené na modeli ľudského neurónu. V tejto podsekcii vysvetlíme biologickú stavbu neurónu, ako aj jej matematickú aproximáciu používanú ako základ neuronových sietí.

#### 4.2.1. Biologický neurón

Biologické neuróny sú zložitejšie ako umelé neuróny neuronových sietí aj štruktúrou aj funkciou. Biologický neurón sa skladá z tela neurónu, dendritu, jadra, synapsie, bazálneho dendritu a axónového vlákna.

## 4.2.2. Matematický neurón - perceptron



Obrázek 4.1: Matematický model neurónu - perceptron, Zdroj: Autor, podľa [4]

Matematická reprezentácia neurónu nemá analogickú štruktúru, ale iba princíp fungovania. Teda je to systém, ktorý na sumuje vstupy a na ich základe vytvára výstup. V umelom neuróne sú vstupné informácie vážené váhami (weights). Následne sa odčíta prahová hodnota (threshold alebo bias) a aktivačnou funkciou (activation function) sa signál transformuje na výstupný signál, ktorý je následne predaný ďalším neurónom v nasledujúcej vrstve siete.

Najjednoduchší typ neurónovej siete je tzv. perceptron, ktorý bol navrhnutý F. Rosenblat-om. Ide o jednovrstvovú sieť s jediným neurónom. Vstupom je  $R$  hodnôt, označených  $p_1, p_2, p_3, \dots, p_R$ , pričom tieto hodnoty sú násobené váhovými koeficientami  $w_1, w_2, w_3, \dots, w_R$ . Vplyv má aj spomínaná prahová hodnota  $b$  bias. Platí teda:

$$n = w_1 * p_1 + w_1 * p_1 + w_1 * p_1 + \dots + w_1 * p_1 + b = \sum_{i=1}^R w_i p_i + b \quad (4.1)$$

**Prehľad často používaných aktivačných funkcií** Ako aktivačnú funkciu sa dá použiť v podstate ľubovoľná funkcia, no je vhodné používať funkcie, ktoré účelovo transformujú signály medzi vrstvami tak aby pomohli riešeniu vybraného problému. V [4] sú uvedené tieto často používané aktivačné funkcie, kde  $a$  je výstup a  $n$  je vstup.>

- hardlim - ak  $n < 0$ , tak  $a = 0$ , inak  $a = 1$
- purelin -  $a = n$
- logsig (alebo sigmoid)-  $a = \frac{1}{1+e^{-n}}$
- tansig (alebo tanh) -  $a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$
- hardlims - ak  $n < 0$ , tak  $a = -1$ , inak  $a = 1$
- satlin -  $a = 0$  pre  $n < 0$ ;  $a = n$  pre  $-1 \leq n \leq 1$ ;  $a = 1$  pre  $n \geq 1$

- satlins -  $a = -1$  pre  $n < 0$ ;  $a = n$  pre  $1 \geq n \geq -1$ ;  $a = 1$  pre  $n \geq 1$
- radbas -  $a = e^{-n^2}$

K tomuto zoznamu môžeme tiež pridať aktivačné funkcie ReLU a softmax, ktoré sa používajú pri vybraných aplikáciách neurónových sietí.


**ReLU** Skratka pre Rectified Linear Unit, je funkcia, ktorá funguje na princípe lineárnej aproximácie ľubovoľnej konvexnej funkcie po častiach. Prakticky ide o lineárnu identitu pre pozitívne čísla a nulu pre negatívne čísla. Jej výhodou je nízka výpočtová náročnosť a rýchla konvergencia, nakoľko linearita eliminuje stagnáciu gradientu pre vysoké vstupy. Tým sa tiež eliminuje problém miznúceho gradientu, ktorý spomíname v kapitole 4.4.2.

$$ReLU(x) = \max(x, 0) \quad (4.2)$$


**Softmax** Funkcia softmax normalizuje jej vstup do intervalu  $\langle 0, 1 \rangle$  a tiež ho mapuje na pravdepodobnostné rozloženie. Táto funkcia je preto často používaná pri klasifikačných úlohách, ako aktivačná funkcia výstupnej vrstvy neurónovej siete. Napríklad si predstavme sieť rozpoznávajúcu tri triedy, teda táto sieť má vo výstupnej vrstve tri neuróny, každý reprezentujúci jednu triedu. Aktivácia softmax tak rozloží jej vstup do týchto troch neurónov, a hodnoty, v týchto neurónoch potom môžeme interpretovať ako percentuálnu reprezentáciu pravdepodobnosti, že ide o triedu danú neurónom.

$$softmax(x) = \frac{e^x}{\sum_k e^x} \quad (4.3)$$

**Achitektúra neurónových sietí** sa všeobecne skladá zo vstupnej vrstvy, skrytých vrstiev a výstupnej vrstvy. Návrh počtu skrytých vrstiev a neurónov v jednotlivých vrstvách sú určujúce pre učiace schopnosti a kvalitu siete, ako aj výpočtovú náročnosť operácií učenia a vyhodnocovania podnetov. Topológia sietí sa niekedy značí aj numericky v tvare, napr. 5-4-4-2, identifikujúca sieť s 5 vstupnými neurónmi 2 skrytými vrstvami po 4 neurónoch a výstupnou vrstvou s 2 neurónmi.



Obrázek 4.2: Aktivačné funkcie zľava-doprava - sigmoid, tanh, ReLU a softmax, Zdroj: Autor



Obrázek 4.3: Schéma jednoduchéj viacvrstvovej neurónovej siete, Zdroj: Autor, podľa [12]

**Over a underfitting** V prípade, že sieť obsahuje príliš málo vrstiev a neurónov, nebude schopná správne zachytiť a modelovať vzťahy medzi vstupnými dátami, čo vedie k tzv. 'underfitting' alebo stavu, kedy sieť nemá dostatočnú kapacitu na presné zachytenie nuancií v dátach. Opačom je, keď príde k overfittingu, kedy je sieť príliš komplikovaná a tak modeluje aj závislosti založené na šume prítomnom vo vstupných dátach. To vedie k slabej generalizácii siete a napriek dobrým výsledkom na tréningových dátach nebude v produkčnom prostredí dosahovať dobré výsledky.

## 4.3. Typy neurónových sietí

Neurónové siete sa všeobecne klasifikujú v závislosti na spôsobe učenia na siete s učiteľom a bez učiteľa a podľa schopnosti práce so vstupmi na siete statické a dynamické.

### 4.3.1. Siete s učiteľom

Siete s učiteľom sú vhodné na modelovanie dynamických systémov, klasifikáciu dát skreslených šumom a predikciu dát. Pri učení s učiteľom sú vstupné dáta rozdelené minimálne na dve časti - tréningové dáta a testovacie dáta -, ale zvyčajne na tri časti, kde sa časť dát oddelí na validáciu. Učiteľ tiež musí poskytnúť pravdivé očakávané výstupy, aby sieť mohla overiť svoje schopnosti.

**Trénovacie dáta** sú použité na vlastný výpočet gradientu a úpravy váh a biasov siete. Tu prichádza k učeniu neurónovej siete.

**Na validačných dátach** je v priebehu učenia sledovaná chyba, ktorá by sa mala znižovať s postupnou zvyšujúcou sa schopnosťou siete modelovať daný problém. Akonáhle začne prichádzať k preučeniu, alebo overfittingu, siete, začne chyba na validačných dátach rásť, čo indikuje zhoršujúcu sa schopnosť siete generalizovať. Preto sa zvyčajne používajú váhy a biasy siete z momentu, kedy je validačná chyba minimálna, aby sa zachovala schopnosť siete generalizovať na predtým nevidených dátach.

**Testovací dataset** nie je použitý v rámci učenia a slúži na porovnanie rôznych modelov a overenie schopnosti generalizovať poznatky siete. Rozdiel medzi časom, kedy dosiahne testovacia a validačná chyba svoje minimum môže naznačovať nevhodné rozdelenie dát do týchto setov, zvyčajne kvôli tomu, že jeden z datasetov nie je reprezentatívnou podmnožinou celku, čo do reprezentácie podmnožín a trendov.

### 4.3.2. Siete bez učiteľa

Siete, ktoré sa trénujú bez učiteľa nevyžadujú žiadne vonkajšie kritérium správnosti a zväčša sa používajú na hľadanie vzorov v dátach, na základe ktorých ich identifikujú. Ako príklad použitie môžeme spomenúť identifikáciu zhlukov dát, na základe minimálnej vzdialenosti od centra zhukov.

### 4.3.3. Statické a dynamické siete

Pri delení na statické a dynamické siete rozoznávame siete podľa smeru výpočtu odozvy. Statické siete sú tzv. feedforward typu, teda výpočet odozvy prebieha dopredne smerom od vstupu k výstupu. Pri dynamických sieťach odozva nezávisí iba od vstupu ale aj od predchádzajúcich vstupov, výstupov alebo stavov siete. Dynamické siete môžeme ďalej rozdeliť na siete obsahujúce spätnú väzbu (tzv. rekurentné siete) a dopredné dynamické siete. Dopredné dynamické siete sa odlišujú od sietí statických obsahom tzv. tapped delay line (TDL), ktorá ich spája s predchádzajúcimi vstupmi, odozva teda závisí od celej vstupnej sekvencie, nielen jednotlivých vstupov.

### 4.3.4. Algoritmy učenia

Pri výpočte váh neurónovej siete s učiteľom je cieľom optimalizačného algoritmu nájsť globálneho extrém - minima - chyby pre daný parameter úlohy. Chyba  $E$  (error) je rozdiel medzi hodnotami vstupnej závislej premennej  $\mathbf{a}$  (target) a vypočítanej hodnoty tejto premennej  $\mathbf{o}$  (actual). Výpočet teda spočíva v postupe, kde sa najprv spraví výpočet výstupov na základe vstupov a váh, a následne sa vypočíta chyba  $\mathbf{E}$ . Výpočet sa robí pre všetky výstupy a v každom cykle učenia. Tento rozdiel sa využije k spätnému výpočtu váh a proces sa opakuje tak dlho, až chyba  $E$  konverguje k nami akceptovateľnej hodnote. Proces učenia teda môžeme interpretovať ako optimalizačnú úlohu s účelovou funkciou  $\mathbf{E}$  definovanou v hyperpriestore, pri ktorom sa hľadá jej minimum.

#### Back propagation

Algoritmus Back Propagation je metódou spätnej propagácie chyby s následnou úpravou váh spojení umelých neurónov spomínanej v nadradenej sekcii. Back propagation algoritmus robí postupné kroky pomocou algoritmu gradient descent, ktoré tak približujú chybu lokálnemu alebo globálnemu minimu. Globálne minimum je teoretickým najlepším riešením a reprezentujúce najmenšiu možnú chybu, ale jeho dosiahnutie býva veľmi výpočtovo náročné, ak nie nemožné, preto sa uspokojíme s jeho blízkou aproximáciou. Váhy siete sú optimalizovaná tak, že po každom pohybe vypočítanej chyby príde k proporčnej úprave váh (proporčnej k vplyvu daných váh na výstup, teda chybu, siete). Ešte pred zahájením učenia bývajú váhy jednotlivých neurónov náhodne inicializované. Zjednodušene môžeme algoritmus Back propagation definovať nasledovne:

1. Pre vstup  $x$  vypočítaj aktivačné funkcie v prvej vrstve
2. Vypočítaj aktivačné hodnoty dopredne vo všetkých nasledujúcich vrstvách, kombinovaním hodnôt aktivačných funkcií neurónov z minulej vrstvy, ich váh a biasu
3. Vypočítaj chybu na výstupe, teda ako ďaleko je výsledok od výsledku požadovaného
4. Na základe chyby spätne uprav váhy a biasy neurónových spojení vypočítaním partiálnych derivácií loss funkcie a z nich získanými gradientami
5. Opakuj s nasledujúcim vstupom

## Optimizátory učenia neurónových sietí

V tejto podsekcii spomenieme niekoľko typov optimalizačných algoritmov používaných na mieste obyčajného gradientového zostupu v back propagation algoritme.

**Conjugate gradient descent** Konjugovaný gradientový zostup (CGD) je variatnom algoritmu gradientového zostupu. Podobne ako obyčajný GD, aj CGD robí postupnosti krokov, avšak miesto voľby smeru najstrmšieho zostupu je smer každého kroku určený konjugovaným gradientom, ktoré algoritmus už vypočítal.

**RMSProp** RMSProp je založený na stochastickom gradientovom zostupe s momentom, avšak s modifikovaným výpočtom gradientov. To umožňuje rýchlejšiu konvergenciu, nakoľko zmena výpočtov limituje oscilácie krokov gradientového zostupu, a tak umožňuje algoritmu robiť väčšie kroky.

### 4.3.5. Transfer Learning

Transfer learning je metódou zlepšenia, prípadne urýchlenia tréningu modelu strojového učenia znova použitím už existujúceho modelu. V [23] je prehľad prístupov k transfer learningu, avšak pre potreby tejto práce nám bude stačiť jednoduchý spôsob založený na prenose naučených vrstiev existujúceho modelu do nového modelu. V praxi to znamená, že vybrané vrstvy novej siete inicializujeme váhami z už existujúceho modelu. Tým sa preniesli znalosti predošlého modelu, a následne pri tréningu nového modelu zablokujeme menenie týchto prenesených váh a povolíme ho iba v nových vrstvách.

### 4.3.6. Vyhodnocovanie tréningu neurónových sietí

Hodnotenie prediktívnych modelov je zvyčajne založené na meraní rozdielov medzi predpovedanými a skutočnými hodnotami výstupných veličín. V [12] sú predstavené základné spôsoby hodnotenia pre klasifikačné a regresné modely neurónových sietí. Tu poskytujeme ich prehľad a vzorce podľa ktorých sa počítajú prevzaté z [12].

#### Hodnotenie regresných modelov

Najrozšírenejšie hodnotiace funkcie pre regresné modely sú stredná kvadratická chyba (MSE) a stredná absolútna chyba (MAE). MAE vypočítame nasledovne:

$$S_{MAE}(M, \theta) = \frac{1}{n} \sum_{i=1}^n |\hat{y}(i, M, \theta) - y(i)| \quad (4.4)$$

Výpočet MSE je ekvivalentný, ale nepočíta s absolútnou hodnotou rozdielu  $\hat{y}(i, M, \theta) - y(i)$ . Variantom týchto funkcií je ešte stredná absolútna relatívna chyba (MAPE).

$$S_{MAPE}(M, \theta) = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}(i, M, \theta) - y(i)|}{y(i)} \quad (4.5)$$

MAPE berie navyše do úvahy aj relatívnu chybu, teda podiel absolútnej chyby a predpovedanej hodnoty.

## Hodnotenie klasifikačných modelov

Obdobou MSE je pre klasifikačné úlohy stredná klasifikačná chyba počítaná nasledovne:

$$S_{0/1}(M, \theta) = \frac{1}{n} \sum_{i=1}^n I(\hat{y}(i, M, \theta), y(i)) \quad (4.6)$$

Kde  $I(a, b) = 1$ , ak  $a = b$ , inak  $I(a, b) = 0$ . Často je však správna klasifikácia jednej z tried dôležitejšia ako tie zvyšné. Pre vizualizáciu môžeme pri testovaní modelu generovať tzv. maticu zámen (confusion matrix). Tá ma tvar matice kde zobrazujeme počty predpovedaných a skutočných tried v testovanom datasete a v bunkách matice teda vidíme počet správne označených príkladov true positives(TP), správne neoznačených true negatives(TN) a chyby, nesprávne neoznačených false negative(FN) a nesprávne označených false positive(FP). Na príklade s dvoma triedami **yes** a **no** by matica vyzerala nasledovne:

	Predicted YES ( <i>yes'</i> )	Predicted NO( <i>no'</i> )
Actual YES (yes)	TP	FN
Actual NO (no)	FP	TN

Tabulka 4.1: Definícia matice zámen, Zdroj: Autor.

Na základe týchto počtov sa potom spočítavajú ukazovatele accuracy(správnosť), recall(alebo senzitivita), precision(presnosť). Tie počítame nasledovne:

$$Accuracy = \frac{(TP + TN)}{total} \quad (4.7) \quad Recall = \frac{TP}{yes} \quad (4.8) \quad Precision = \frac{TP}{yes'} \quad (4.9)$$

Ďalším ukazovateľom zvykne byť tzv. F1 score, ktoré je váženým priemerom senzitivity a presnosti.

## 4.4. Vybrané typy neurónových sietí

V tejto sekcii v krátkosti predstavíme niekoľko typov neurónových sietí, s ktorými budeme v rámci tohto textu pracovať.

### 4.4.1. Konvolučné siete

Konvolučné siete sú typom viacvrstvového perceptronu využívané často na rozpoznávanie obrazu, klasifikáciu obrázkov, či spracovanie prirodzeného jazyka. V kontexte tejto práce budeme používať konvolučnú sieť na klasifikáciu obrázkov. Obecne sa konvolučné siete skladajú z konvolučných vrstiev, tzv. pooling vrstiev a plne prepojených vrstiev, zvyčajne v architektúre vstup - konvolučná - konvolučná - pooling - ... - plne prepojená - výstup.

#### Princíp fungovania

Pri rozpoznávaní obrazu môžeme počítaču dať iba informácie o pixeloch, teda si môžeme predstaviť obraz ako maticu hodnôt s výškou a šírkou veľkosti obrázku (v pixeloch), ale



prítomnú v troch kanáloch (RGB - podľa spôsobu akým počítače reprezentujú farbu). V konvolučných vrstvách dochádza k vytváraniu filtrov - malých okien, ktoré sa pozerajú iba na malý výrez klasifikovaného obrazu, ktorý je tiež predstavený maticou a sú v ňom definované váhy. Následne prebieha konvolúcia, alebo násobenie po elementoch, medzi hodnotami filtra a hodnotami z obrazu postupne po malých výrezoch (po jednej konvolúcii sa sledovaný výrez obrazu posunie o veľkosť filtra). Postupne potom dochádza k posúvaniu tohto filtra vždy o jeden pixel a následne spočítaniu ďalších konvolúcií, až kým neprejde celý obraz. O filtroch môžeme premýšľať ako o rozpoznávačoch určitých tvarov, napr. vertikálnych a horizontálnych čiar. Postupnou konvolúciou celého obrazu sieť zistí, kde sa na ňom nachádzajú vertikálne čiary, následne vymení filter za iný a postup opakuje. Výsledkom konvolúcie sú vysoké čísla, kde je filter podobný tvaru na výreze, a malé čísla, kde je tvar rozdielny.

V pooling vrstvách dochádza k downsamplingu, zvyčajne vo forme redukcie matice z konvolučnej vrstvy na niekoľko menších regiónov, z ktorých sa vyberie maximálna hodnota. Takto zredukovaná matica sa následne použije v ďalšej vrstve, aby sa znížili nároky na pamäť, ale aj predišlo overfittingu.

V každej ďalšej vrstve sú detekované zložitejšie obrazce, až kým dôjdeme na k poslednej plne prepojenej vrstve, ktorá je priamo napojená na Y výstupov, reprezentujúcich Y kategórií, ktoré rozpoznávame. Tu prebieha korelácia medzi zložitými obrazcami (nohy, rohy, atď.) a rozpoznávanými kategóriami.

#### 4.4.2. Rekurentné siete

Rekurentné neurónové siete (RNN), na rozdiel od klasických dopredných sietí, pri prechode informácie neurónom neberú do úvahy len aktuálny vstup, ale aj hodnotu predošlého vstupu. Neuróny v RNN teda majú váhy nie len pre spojenia s neurónmi v nižšej vrstve, ale aj váhu pre ich minulé hodnotu, a obe sa upravujú počas tréningu. Kvôli tomu sa RNN učia modifikovaným algoritmom back propagation, zvaným "Back propagation through time". To dáva RNN lepšiu schopnosť učiť sa z dát, ktoré sa zvyčajne vyskytujú v sekvenciách, teda poskytujú informácie o vstupoch, ktoré prídu ďalšie, ako napríklad prirodzený jazyk alebo dáta merané v čase. Ďalším rozdielom RNN je schopnosť mapovania nielen one-to-one, ale aj one-to-many, many-to-one a many-to-many. Klasické dopredné siete mapujú iba vstupy na výstupy, teda one-to-one.

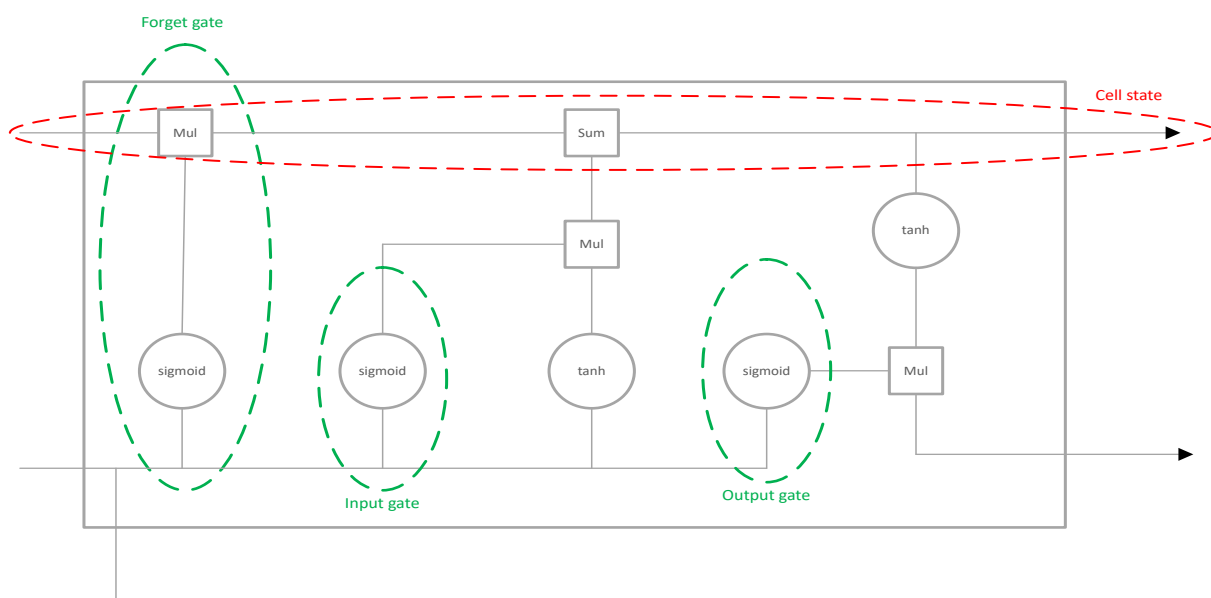
**Back propagation through time** Back propagation through time si môžeme jednoducho predstaviť ako back propagation na tzv. "rozvinutej" rekurentnej sieti. Rozvinutie RNN je abstraktná pomôcka, kedy si môžeme RNN predstaviť ako sériu dopredných neurónových sietí, kedy pre každý ďalší vstup sa pripojí nová sieť na koniec série, čo nám lepšie dovoľí pochopiť koncept upravovania váh v RNN. V RNN totiž vypočítaná chyba, určujúca odchýlku od očakávanej odpovede, závisí nielen od terajšieho vstupu, ale aj od vstupu predošlého. Takže chyba a následná úprava váh je spätne propagovaná od posledného vstupu v čase smerom k prvému, cez všetky rozvinuté minulé vstupy.

RNN, podobne ako iné deep networks sa však stretávajú s dvoma typmi problémov, tzv. "explodujúcimi" a "miznúcimi" gradientmi. K explodujúcim gradientom dôjde pri akumulácii chyby počas back propagation, čo spôsobí nárast váh neurónov na veľmi vysoké čísla, čo následne interferuje s učiacimi schopnosťami siete. Podobne miznúce gradienty sú

zrkadlovým problémom, kedy sa akumuláciou chyby stane, že váhy sa budú limitne blížiť k 0 a vzniknú nám tak tzv. mŕtve neuróny, ktorých hodnota sa kvôli váhe 0 už ďalej v sieti nevyužije k rozhodovaniu ani učeniu. Tieto problémy vyriešili autori článku [8], kde predstavujú Long-Short Term Memory sieť, ktorá je typom RNN eliminujúcim problémy miznúcich a explodujúcich gradientov.

## Long-Short Term Memory siete

LSTM siete sú teda špeciálnym typom RNN, ktoré boli pôvodne explicitne navrhnuté pre zlepšenie schopností dlhodobej pamäte rekurentných sietí. RNN by mali byť teoreticky schopné si pamätať aj vplyv vzdialených predošlých vstupov, avšak v praxi to nebolo celkom pravdou. Architektúra RNN implementuje pamäť jednoduchým pridaním predošlého vstupu pomocou aktivačnej funkcie (napr. tanh), môžeme teda hovoriť o jednovrstvovej architektúre. V architektúre LSTM sietí je tento jednoduchý spôsob nahradený až štyrmi vrstvami, usporiadanými do troch brán (gate), ktoré interagujú s tzv. "cell state", ktorý si môžeme predstaviť ako funkciu informácií o predošlých vstupoch.



Obrázek 4.4: Schéma neurónu siete typu Long-Short Term Memory, Zdroj: Autor, podľa [14]

**Forget Gate** Forget gate je tvorená jednou vrstvou so sigmoidovou aktivačnou funkciou a násobením. Sigmoidová funkcia má obor hodnôt v intervale  $<0,1>$  a násobením jej hodnoty (vypočítanej z aktuálneho vstupu a výstupu predošlej vrstvy) s cell state tak môžeme regulovať aké množstvo informácií z minulých vstupov bude pokračovať do ďalšej vrstvy LSTM siete. Forget gate tiež rieši spomínané gradientové problémy tým, že nedovolí akumulácii priveľkých, či prímalých gradientov a tak predíde explodovaniu, či miznutiu gradientu.

**Input Gate** Opačne od forget gate, input gate reguluje, koľko informácií do cell state pridáme. Je opäť tvorená sigmoidovou vrstvou, avšak teraz v tandeme s vrstvou aktivova-

nou funkciou hyperbolického tangentu. Sigmoidová vrstva určuje, ktoré hodnoty cell state budeme upravovať, a tanh vrstva vyberie nové hodnoty, ktoré sú kandidátom na pridanie. Následne výstupy oboch vrstiev multiplikujeme a pridáme do cell state sumovaním. Hodnoty v oboch vrstvách sú opäť vypočítané z aktuálneho vstupu a zo výstupu z minulej vrstvy.

**Output Gate** Output gate určuje, aký vplyv má cell state na výstup tohto neurónu. Znovu sú tu prítomné vrstvy sigmoid a tanh, najprv vrstva sigmoid určí, ktoré časti kombinácie aktuálneho vstupu a výstupu predchádzajúcej vrstvy zahrnieme vo výstupe tejto vrstvy a tanh, ktorá transformuje hodnoty cell state do intervalu  $<-1,1>$  (obor hodnôt tanh). Následným vynásobením výstupov oboch vrstiev vznikne výstup neurónu.

## 5. Akciové analýzy

Pri obchodovaní na kapitálových trhoch je prirodzene cieľom zhodnotenie vložených finančných prostriedkov. Na dosiahnutie tohto cieľa je nutné mať informácie o tom, kedy je vhodné akcie nakupovať, a kedy ich predávať. Pre kontext tejto práce teda v krátkosti opíšeme tri hlavné metódy akciovej analýzy, s bližším pohľadom na technickú analýzu, ktorá je vzhľadom na jej jednoduchú automatizáciu pre nás najzaujímavejšia. Táto kapitola čerpá z [24]

### 5.1. Fundamentálna analýza

Fundamentálna analýza akcie má za cieľ určiť vnútornú hodnotu akcie, teda cenu na ktorej by sa jej hodnota na trhu ustálila pri zhode ponuky a dopytu. Pri určovaní vnútornej hodnoty vlastne odhadujeme budúci diskontovaný cash flow - vyplatené dividendy a realizovaný diskontovaný kapitálový výnos. Problémom je, že jednotlivé podniky sú vysoko ekonomicky previazané so svojím okolím, či už v odvetví, v ktorom pôsobia, alebo v rámci národného hospodárstva, atď. Preto je v rámci fundamentálnej analýzy potrebných niekoľko ďalších analýz, kým môžeme spraviť informovaný odhad vnútornej ceny akcie. Princípom však je zistiť, či je vnútorná cena akcie vyššia alebo nižšia ako jej aktuálna cena na trhu a tak zistiť, či je akcia nadhodnotená alebo podhodnotená. Nadhodnotená akcia je signálom na predaj a podhodnotená naopak signálom pre nákup akcie.

### 5.2. Psychologická analýza

Psychologická analýza sa opiera o vplyv psychiky obchodníka na jeho vlastné chovanie na kapitálových trhoch, a tiež aj o správanie obchodníkov ako súčasť davu (všetkých obchodníkov pôsobiacich na trhu). Vidí jednanie obchodníka ako kombináciu informácií získavaných z okolia (ceny akcií, výsledky fundamentálnej a technickej analýzy) a vlastností obchodníka samotného (sklon k riziku, osobnostné charakteristiky, atď.). Existuje niekoľko koncepcií, pre ilustráciu tu môžeme uviesť Kostolanyho burzovú psychológiu, či Teóriu špekulatívnych bublín.

### 5.3. Technická analýza

Technická analýza sa snaží odhadnúť budúcu trhovú cenu akcie na základe cien minulých. Používajú sa v nej grafické a matematické metódy, ktoré predpokladajú že kurzy investičných nástrojov sa pohybujú v trendoch a že zoskupením niekoľkých rôznych trendov vznikajú vo vývoji kurzov vzory alebo formácie, ktoré majú tendenciu sa opakovať. V [24] sú základné myšlienky zhrnuté do troch téz:

1. Všetky informácie, ktoré sú zverejnené a súvisiace s daným investičným nástrojom sú zohľadnené v jeho kurze (cene).
2. Vo vývoji kurzov existujú vzory vo všetkých časových horizontoch - krátkodobom, strednodobom aj dlhodobom

### 3. Tieto vzory sa za určitých podmienok opakujú

Z pohľadu delenia metód môžeme okrem spomínaného delenia na grafické a matematické metódy (alebo technické indikátory) použiť aj delenie na leading a lagging metódy a indikátory.

- Leading metódy a indikátory analytikovi pomáhajú predpovedať, ktorým smerom sa bude kurz vyvíjať, teda či bude pokračovať v trende, alebo sa trend otočí. Tieto indikátory je vhodné použiť, ak nie je na trhu silný trend.
- Lagging metódy a indikátory informujú o momentálne prebiehajúcom trende alebo jeho zmene, ktorá už nastala. Sú dobrým zdrojom informácií na trhu so silným trendom.

## 5.4. Grafické metódy

Grafické metódy technickej analýzy inak nazývané aj charting využívajú grafy na identifikáciu dĺžky a sily trendu vo vývoji kurzu k odhadovaniu jeho zmeny. Medzi používané grafy patria napríklad Line Chart, Bar Chart, Candlestick Chart a iné. Medzi pokročilé grafické metódy patrí aj spomínaná Elliottova vlnová teória, ktorej využitie je jedným z predmetov tejto práce, a preto sa ňou budeme bližšie zaoberať v sekcii 6.

## 5.5. Indikátory technickej analýzy

Existuje množstvo jednotlivých ukazovateľov technickej analýzy, ktoré sa líšia spôsobom konštrukcie, výpovednou hodnotou, spoľahlivosťou, a inými charakteristikami. V tejto práci preberieme delenie popísané v [24] a v nasledujúcich podsekciiach uvedieme hlavné charakteristiky jednotlivých skupín, ako aj popis vybraných ukazovateľov.

### 5.5.1. Trendové indikátory

Do tejto skupiny ukazovateľov patria kľzavé priemery a ukazovatele na nich založené. Ide jednoznačne o lagging ukazovatele, ktoré sú veľmi obľúbené a podobne aj pomerne spoľahlivé.

**Kľzavé priemery** sú používané hlavne na zistenie druhu nastúpeného trendu a na identifikáciu a potvrdenie jeho zmien. Všeobecne sa počítajú ako priemerný kurz investičného nástroja alebo priemernú hodnotu indikátory za určité obdobie, ktoré je každý vybraný časový úsek upravované, teda príde k odstráneniu najstaršej hodnoty a pridaniu najnovšej. V praxi sa používa niekoľko druhov kľzavých priemerov, ktoré sa líšia spôsobom konštrukcie. Spomenúť môžeme jednoduchý (všetky hodnoty majú rovnakú váhu), vážený (novším hodnotám pribúda váha lineárne) a exponenciálny kľzavý priemer (novšie hodnoty majú váhu exponenciálne vyššiu).

**Bollingerove pásy** Bollingerove pásy vznikajú vertikálnym posunutím jednoduchého kĺzavého priemeru nahor a nadol o určitý počet smerodajných odchýlok kurzu analyzovaného investičného nástroja. Týmto vznikne pásmo, ktorého šírka je naviazaná na volatilitu kurzu a umožňuje zohľadniť charakter a silu trendu. Pôvodne ich zakladateľ John Bollinger konštruoval s použitím 20-dňového kĺzavého priemeru a posunom o  $\pm$  dve smerodajné odchýlky. Pre praktickú interpretáciu je nadefinovaných niekoľko charakteristík:

1. Ostré zmeny v kurze majú tendenciu sa objavovať po zúžení pásov, teda pri poklese volatility
2. Ak sa kurz dostane výrazne mimo pásmo, tak sa očakáva pokračovanie trendu
3. Vrcholy a dná mimo pásmo nasledované vrcholmi a dnami v pásme signalizujú zmenu trendu
4. Pohyb kurzu, ktorý začína na jednom páse má tendenciu pokračovať aj do pásu druhého

**Parabolic SAR** Parabolic Stop and Reversal je ďalším lagging indikátorom, ktorý slúži na stanovenie stop-signalov a obrátov v trende. Tento ukazovateľ je konštruovaný pomocou nasledujúceho vzorca:

$$SAR_0 = SAR_{-1} + a(P_{ex} - SAR_{-1}) \quad (5.1)$$

Tu  $SAR_0$  je hodnota indikátoru pre daný obchodný deň,  $SAR_{-1}$  je hodnota indikátoru pre predošlý deň,  $a$  je akceleračný koeficient a  $P_{ex}$  je extrémny bod - maximum (pri rastúcom) alebo minimum podľa aktuálneho smeru trendu. Indikátor je interpretovaný na základe vystúpenia kurzu nad alebo pod krivku Parabolic SAR, ktorá je zakresľovaná nad kurz v prípade klesajúceho trendu a pod kurzom pri stúpajúcom trende. Princípom je, že väčšina trendov kopíruje tvar paraboly, s pomalším rozbehom a následne akceleráciou až do bodu vysilenia. Krivka Parabolic SAR, vďaka akceleračnému koeficientu, tak kopíruje tento tvar a keď príde k predbehnutiu trendu touto krivkou, tak to je signálom pre nákup alebo predaj.

### 5.5.2. Cenové indikátory

Ukazovatele z tejto skupiny sú postavené a kalkulované na údajoch o kurzoch, resp. cenách investičných inštrumentov. Mnoho z nich má charakter oscilátorov, ktorých hodnota kolíše okolo stanovenej úrovne, alebo pásma. Ich konštrukcia je založená zvyčajne založená na rozdiel, či podiele dvoch alebo viacerých kurzových hodnôt. Ich interpretáciou sa dajú zisťovať oblasti podkúpeného a presýteného trhu alebo divergenciou vývoja oscilátoru a kurzu môžeme pozorovať zmeny v trendov.

**Price Rate of Change** Price ROC je oscilátor, ktorý osciluje okolo línie 0 a tým vypovedá o zrýchlení, či spomalení trendu, jeho zmene a charaktere. Najviac používanou verziou je meranie percentuálnej zmeny kurzu za posledných  $n$  časových období (dnov, týždňov, atď., najčastejšie 12 a 25 denné). Rast indikátora je odrazom rastu kurzu a naopak. Price ROC vypočítame nasledovne:

$$PROC = \frac{dnesnyKurz - kurzPredN}{kurzPredN} * 100 \quad (5.2)$$

Interpretácia Price ROC sa často používa na určovanie podkúpeného alebo presýteného trhu.

### 5.5.3. Objemové indikátory

Táto skupina ukazovateľov, ako názov napovedá, pracuje na základe objemu obchodov, prípadne spojených s informáciami o kurze. Môžeme ich považovať za ukazovatele sily trhu, kde silný trend je sprevádzaný rastúcim objemom obchodov a prudký pokles objemu naopak signalizuje oslabenie trendu, ktoré môže vyústiť až do jeho zmeny.

**Volume rate of change** Volume ROC je indikátor analogický k Price ROC, teda ide o percentuálnu zmenu objemu za niekoľko posledných období. Odchýlenie od stredovej línie smerom hore alebo dole znamená silu prebiehajúcej tendencie trhu (rast alebo pokles). Výpočet je taktiež analogický k Price ROC:

$$PROC = \frac{\text{dnesnyObjem} - \text{objemPredN}}{\text{objemPredN}} * 100 \quad (5.3)$$

**Price and Volume Trend** PVT je leading indikátorom, ktorý meria smer toku objemu obchodov, teda či objem plynie "do" alebo "zo" sledovaného investičného nástroja. V závislosti na charaktere zmeny kurzu PVT k svojej včerajšej hodnote pričíta, alebo odčíta objem obchodov proporčne k percentuálnej zmene kurzu. Výpočet PVT je definovaný nasledovne:

Ak  $P_0 > P_{-1}$ :

$$PVT_0 = PVT_{-1} + (V_0 \frac{P_0 - P_{-1}}{P_{-1}}) \quad (5.4)$$

Ak  $P_0 < P_{-1}$ :

$$PVT_0 = PVT_{-1} - (V_0 \frac{P_0 - P_{-1}}{P_{-1}}) \quad (5.5)$$

V špeciálnom prípade, že nepríde k zmene kurzu, tak nepríde ani k zmene PVT, teda  $PVT_0 = PVT_{-1}$ . Na základe PVT môžeme hovoriť o signále k nákupu, ak PVT začne náhle stúpať, ale kurz ešte klesá. Naopak signálom k predaju nástroja je negatívna divergencia PVT a kurzu, teda ak PVT začne náhle klesať, zatiaľ čo kurz ešte rastie.

### 5.5.4. Indikátory sentimentu

Sentiment indikátory sa pokúšajú zachytiť nálady, emócie a chovanie účastníkov trhu. Ich základom je predpoklad, že psychologické aspekty sú signifikantným kurzotvorným faktorom na trhu. V rámci sentiment indikátorov rozlišujeme tzv. **cyklické**, ktoré sa riadia chovaním profesionálnych investorov (spravidla úspešných), a **anticyklické** ukazovatele, ktoré sledujú chovanie širokej investorskej verejnosti.

**Barron's Confidence Index** BCI je cyklický indikátor sledujúci situáciu na trhu štátnych a podnikových dlhopisov. Je založený na predpoklade, že situácia na trhu dlhopisov o niekoľko týždňov alebo mesiacov predbieha situáciu na trhu akcií. BCI informuje o predpokladanej úrovni rizika na trhu. Spravidla sa BCI počíta ako pomer medzi výnosovou mierou zo štátnych dlhopisov vysokej kvality (napr. 10 najbonitnejších) a výnosovou

mierou z podnikových dlhopisov priemernej kvality (napr. priemerná výnosová miera Dow-Jones dlhopisového indexu zo 40 dlhopisov). Ak hodnota BCI vzrastie na zhruba 85 až 95, tak to signalizuje stúpajúci trend, ktorí sa s oneskorením prenesie aj na akciový trh, teda je pre analytika nákupným signálom, keďže očakávame nárast kurzov. Naopak pokles pod 80 (presné čísla záležia od analyzovaného trhu a časového obdobia) je signalizuje príchod klesajúceho trendu a je teda signálom na predaj.

### **5.5.5. Indikátory šírky a výkonnosti trhu**

Poslednou skupinou indikátorov technickej analýzy sú indikátory šírky a výkonnosti trhu. Tie sú indikátormi globálnych trendov, založených na premise, že pri rastúcom trhu prevyšuje počet rastúcich akcií počet klesajúcich akcií a naopak. Ak počet rastúcich akcií začne pri rastúcom trhu prudko klesať je pravdepodobné, že dôjde k oslabeniu, prípadne zmene trendu.



## 6. Elliottova vlnová teória

Vlnovú teóriu predstavil R. N. Elliott v 30. rokoch minulého storočia v jeho knihe *The Wave Principle*, kde popisuje spôsob analýzy akciového trhu na základe ním definovaných vlnových konštrukcií. V rámci tejto sekcie budú prezentované základy Elliottovej vlnovej teórie, ako sú popísané v [19].

### 6.1. Základy teórie

Elliottova teória je založená na hierarchickom systéme rôznych typov vln, pod ktorými si môžeme predstaviť pohyb ceny akcie alebo iného aktíva. Elliott pomenoval deväť stupňov vln - veľký supercyklus, supercyklus, cyklus, primárne, stredné, malé, menšie, najmenšie a minimálne vlny. Tieto typy tvoria hierarchiu tak, že každý typ vlny sa skladá z nižšieho rádu vln. Teda napríklad vlna cyklus sa skladá z primárnych vln, ktoré ďalej môžeme rozložiť na stredné vlny, ktoré sú zložené z malých vln, atď. Môžeme teda povedať, že vlny majú fraktálny charakter.

Základným vzorom Elliottovej teórie je päťvlnový pohyb, ktorý ide buď v smere alebo proti smeru pohybu vlny vyššieho stupňa. Ak ide o pohyb v smere, tak hovoríme o vlne v hybnom režime, ak naopak, tak o vlnu v režime korekčnom. Najtypickejším predstaviteľom hybného režimu je **impulz**. Impulz môže byť hybný v zmysle rastu, ale aj poklesu ceny aktíva. Impulzné vlny musia spĺňať nasledujúce pravidlá (pre rastúci impulz, pravidlá sú otočené pre impulz klesajúci):

1. Vlna 2 nikdy nevstupuje do zóny vlny 1
2. Vlna 3 nikdy nie je najkratšia
3. Vlna 4 nikdy nevstupuje do zóny vlny 1, resp. žiadna časť vlny 4 nie je totožná s vlnou 2

V prípade, že tieto pravidlá nie sú dodržané nepôjde o impulz, ale o korekciu. Impulzy môžeme rozdeliť na dva typy:

1. Trendové - majú tri vlny v hybnom režime (vlny 1, 3, 5) a dve v korekčnom (vlny 2, 4)
2. Terminálne - terminálny impulz nespĺňa tretie pravidlo impulznej vlny, často na seba beria trojvlnovú podobu a signalizuje, že bude nasledovať ostré otočenie trendu

Korekčné vlny sú všeobecne trojvlnové a pôsobia proti hybným vlnám. Treba si však dať pozor, nakoľko sú pojmy hybné a korekčné vlny relatívne a teda závislé od toho, vzhľadom ku ktorým ďalším vlnám ich analyzujeme.


### 6.2. Hybné vlny

Hybné vlny sa pohybujú rovnakým smerom, ako vlna o stupeň vyššie. Pre vlny z päťvlnovej formácie hybnej vlny platí, že  $2 < 1$  a  $3 > 4$  a  $3 > 1$  a vlna 3 je aj najväčšou z vln

1, 3 a 5. Medzi hybné vlny zaraďujeme už spomínané trendové a terminálne impulzy. Aj keď základné impulzy sú päťvlnové formácie, tak existujú dva javy, pri ktorých sa dĺžka týchto formácií môže zmeniť.

**Predĺženie impulzu** je častým javom, kedy sa podvlna v hybnom režime (1, 3, 5) rozčlení alebo rozvinie do vln nižšieho stupňa a teda z päťvlnového impulzu sa stane deväťvlnová postupnosť. Najčastejšie prichádza k predĺženiu vlny 3, a navyše je aj možné, že sa predĺženie vyskytne aj rekurzívne opäť vo vzniknutej formácii nižšieho stupňa.

**Zlyhaním impulzu** nazývame situáciu, kedy sa vlna 5 nedostane za vrchol vlny 3.




Obrázek 6.1: Impulz a predĺženie impulzu, Zdroj: Autor, podľa [19]

### 6.3. Korekčné vlny

Korekcie postupujú proti smeru vlny vyššieho stupňa a majú vždy trojvlnový charakter. Korekcie sa delia do štyroch skupín:

1. Cikcak - môže sa vyskytovať aj v zložení z podvln v tvare 5-3-5
2. Rovina - vyskytuje sa aj v zložení z podvln v tvare 3-3-5
3. Trojuholník - ten ešte delíme na zužujúci sa a rozširujúci sa a ďalej podľa trendu na vzostupný, zostupný alebo symetrický
4. Kombinácia - je zložená z jednoduchších typov korekcií, ale cikcak a trojuholník sa v nej vyskytujú maximálne raz a to tak, že trojuholník je na jej konci.




Obrázek 6.2: Typy korekcií, zľava doprava - cikcak, rovina a trojuholník, Zdroj: Autor, podľa [19]

## 7. Analýza časových rád

Prístupov k analýze časových rád existuje veľmi mnoho. V tejto krátkej kapitole predstavíme iba analýzu pomocou spojitej vlnkovej transformácie, ktorá je z hľadiska tejto práce zaujímavá.

### 7.1. Spojitá vlnková transformácia

Spojité vlnková transformácia (CWT) sa používa na analýzu signálov. Podobne ako Fourierova transformácia (FT), aj CWT používa vnútorný súčet signálov na meranie ich podobnosti. Rozdielom je, že pri FT sa používa súčet s komplexnými exponenciálami, pri CWT funkciou ktorá slúži na súčet (analýzu) je tzv. vlnka [22]. CWT porovnáva analyzovaný signál s rôzne škálovanou a posunutou vlnkou, ktorej výber závisí iba od toho, čo chceme pomocou CWT zistiť. Príkladom často používanej vlnky je tzv. Morletova vlnka.



Obrázek 7.1: Graf Morletovej vlnky, Zdroj: Autor.

Výsledné koeficienty CWT môžeme následne interpretovať rôznymi spôsobmi, napríklad vo forme scalogramov. Scalogram je grafom absolútnej hodnoty koeficientov CWT ako funkcie času a frekvencie. Na scalograme môžeme dobre pozorovať komponenty signálov s nízkym trvaním a vysokou frekvenciou.

## 7.2. Hurstov exponent

Hurstov exponent  $H$ , ktorý definoval H. E. Hurst v jeho práci [9], je spôsobom merania miery chaotickosti analyzovaného signálu, resp. časovej rady. Exponent nadobúda hodnoty z intervalu  $< 0, 1 >$ , kde  $H = 0.5$  predstavuje najvyššiu mieru chaosu - tzv. Brownov pohyb alebo náhodnú prechádzku. Vývoj signálu s touto hodnotou  $H$  je veľmi ťažké, ak nie nemožné predikovať. Hodnoty  $H < 0.5$  značia, že signál má tzv. anti-perzistentný charakter. Teda má tendenciu sa vracat k svojmu dlhodobému priemeru - po náraste spravidla nasleduje pokles, po ktorom nasleduje nárast, atď. Tendencia ja tým silnejšia, čím je hodnota exponentu bližšie k nule. Na druhej strane ak  $H > 0.5$  tak hovoríme o trendujúcom signále, teda očakávame, že po poklese bude nasledovať pokles a po náraste nárast, aspoň v krátkych časových intervaloch. Opäť platí, že čím je hodnota exponentu bližšie k jednej, tým silnejší je trend.

## 8. Zhrnutie teoretického východiska

V predošlých kapitolách boli predstavené témy z oblastí investičného rozhodovania, neurónových sietí, analýz kapitálového trhu a analýzy časových rád. Tie predstavujú teoretický základ tejto práce. Teória investičného rozhodovania a analýz kapitálového trhu sú dôležité pre uvedenie cieľov práce do širšieho kontextu. Téma spojitaj vlnkovej transformácie a Hurstovho exponentu sú dôležitými súčasťami teoretického východiska kvôli vysvetleniu spôsobu fungovania navrhnutého systému a prepojeniu Elliottovej teórie s neurónovými sieťami. Tematika Elliottovej vlnovej teórie spolu s tematikou neurónových sietí tvoria jadro navrhovaného systému.

Z investičného rozhodovania je pre prácu zaujímavý prístup k investíciám na kapitálovom trhu, ich riziká a možné prístupy k hodnoteniu ich atraktívnosti pre podnik. Vybrané technické indikátory z uvedenej podkapitoly o technickej analýze kapitálového trhu sú použité na tréning referenčnej siete typu LSTM a základné princípy Elliottovej teórie sú využité na vytvorenie datasetu scalogramov, ktorými je následne tréning konvolučná neurónová sieť. Vo fáze testovania navrhnutého systému sú využité prístupy pre hodnotenie klasifikácie, hlavne matica zámen a k nej prislúchajúce ukazovatele.

# 9. Prehľad využitia umelej inteligencie na kapitálových trhoch

Využitie umelej inteligencie je čím ďalej tým rozšírenejšie v podnikovej praxi, report [20] z roku 2018 ponúka prehľad niektorých z najnovších využití umelej inteligencie, hlavne deep learningu, v oblastiach marketingu, pricingu, reklamy, a podpory rozhodovania nielen manažmentu, ale aj radových zamestnancov.

Z pohľadu tejto práce je pre nás zaujímavé využitie spojitej vlnkovej transformácie, Elliottovej teórie a deep learningu v oblasti investícií a obchodu na kapitálovom trhu. Využitie spojitej vlnkovej transformácie na analýzu kapitálového, komoditného a forexového trhu je dobre dokumentované. V [13] je CWT použité na analýzu cyklov cien ropy a v [11] je CWT, konkrétne s Morletovou vlnkou, aplikované na analýzu korelovaných pohybov medzinárodných indexov kapitálového trhu. Skĺbenie aplikácie scalogramov a neurónových sietí taktiež naberá na popularite s rozpoznávaním reči, ako v [2], kde je využitie na analýzu zvukovej scény. Ďalšie využitie tejto kombinácie prístupov sa dá nájsť v medicíne napríklad na detekciu epileptických záchvatov, či ich diagnostiky [6].

Využitie neurónových sietí na predpovedanie pohybov na finančných trhoch je taktiež už pomerne dobre preskúmanou oblasťou. V [3] je popísané využitie doprednej neurónovej siete s klasifikačným prístupom na predikciu trendu komoditných a forexových termínových obchodov. Veľmi zaujímavou je v tejto problematike využitie siete typu Long-Short Term Memory, ktorá figuruje v množstve odborných článkov. Spomenúť môžeme [7], kde autori aplikujú LSTM sieť na predikciu pohybov pre všetky akcie, ktoré tvoria index S&P500 na dátach od roku 1992 do roku 2015. V tomto článku autori preukázali, že použitie LSTM siete dáva lepšie výsledky ako zaužívané prístupy založené na metódach strojového učenia ako logistická regresia a random forest, či aj iné prístupy deep learningu. Porovnanie rôznych architektúr neurónových sietí poskytuje aj [18], v ktorom autori porovnávajú konvolučnú, rekurentnú a LSTM sieť pri predikovaní budúcej hodnoty kurzov akcií. V oblasti aplikovania Elliottovej teórie taktiež prichádza k aplikácii strojového učenia a deep learningu. Príkladom môže byť [26], kde je Elliottova teória využitá na vyvinutie indikátorov, na ktorých je učená neurónová sieť, či [16], kde je rozpoznávanie vzorov Elliottových vln použité na predikciu GBP/USD forexového trhu. Metodológia použitia vzorov Elliottových vln v [16] je založená na [25], kde je predstavený prístup rozpoznávania vzorov Elliottových vln pomocou neurónových a pseudoneurónových sietí.

Na základe rešerše použitých prístupov k predikcii trendu môžeme konštatovať, že samostatne už boli dobre preskúmané oblasti aplikácie ako neurónových sietí, tak Elliottovej teórie a zároveň využitia CWT, či scalogramov. Avšak z tohto pohľadu na stav využívania umelej inteligencie na finančných trhoch môžeme povedať, že ešte nebola veľmi preskúmaná oblasť, kde by boli skĺbené prístupy využitia Elliottovej teórie s využitím spojitej vlnkovej transformácie a scalogramov. Deep learning nám potom poskytuje nástroje, ako napr. konvolučné neurónové siete, na reálnu aplikáciu takéhoto prístupu.

# 10. Implementácia

Táto kapitola obsahuje návrh a popis implementácie nového prístupu k predikcii trendu na kapitálovom trhu založenom na, podľa autorových informácií predtým nepreskúmaným, rozpoznávaní vzorov Elliottovej vlnovej teórie zo scalogramov historického vývoja kurzov akcií pomocou konvolučnej neurónovej siete. Okrem toho je tu uvedený aj návrh a implementácia tradičnejšieho prístupu k predikcii trendu kurzu na kapitálovom trhu pomocou deep learningu založenom na sieti typu Long-Short Term Memory, ktorá je použitá ako báza pre porovnanie využiteľnosti navrhnutej CNN.

## 10.1. Konvolučná neurónová sieť na princípe Elliottovej teórie

V [21] je predstavený prístup k rozpoznávaniu srdcovej arytmie zo scalogramov vytvorených z priebehu EKG. Prístup teda rieši problém rozpoznávania zmeny signálu, čo je aj premisou predpovedania vývoja trendov na akciových trhoch - v sfére technickej analýzy je zmena trendu signalizovaná historickým priebehom kurzu. Preto v tejto práci navrhujeme, podľa autorových informácií, nový prístup k predpovedaniu vývoja trendu na akciových trhoch práve založenom na použití neurónovej siete a scalogramoch vytvorených z historického priebehu kurzu akcie. V tomto prístupe sa opierame o základy Elliottovej vlnovej teórie.

### 10.1.1. Princíp fungovania

#### Elliottova teória

Elliottova vlnová teória pozná vlny hybného a korekčného charakteru - teda impulzy, korekcie typu cikcak, rovina, trojuholník a kombinácia. Teória teda implikuje rozpoznávanie piatich tried, jedna pre každý typ vlny. Bližší pohľad na rozpoznávanie vzorov Elliottových vln z časových rád poskytuje práca [25], kde spolu rozpoznáva až dvanásť vzorov, ktoré môžeme rozdeliť do nasledujúcich kategórií:


- Impulzy - stúpajúce a klesajúce
- Trojuholník - rozširujúci a zužujúci
- Cikcak
- Ideálny priebeh Elliottovej vlny - impulz a následná trojvlnová korekcia

Vzory definované v [25] boli východiskovým bodom pre túto časť diplomovej práce, ukázalo sa však, že využitie týchto vzorov v kontexte scalogramov a konvolučnej neurónovej siete naráža na dva problémy. Tými sú extrakcia týchto vzorov z dát denných kurzov akcií, a ich podobnosť pri prevedení vlnkovou transformáciou do podoby scalogramu. Problém s extrakciou vzorov z dát má dve časti. Po prvé, definícia korekčných vln sa stáva pomerne zložitou, vzory cikcaku a roviny sú ľahko rozpoznateľné expertom, ale ich automatický výber z časovej rady je zložitý, nakoľko sa riadia niekoľkými pravidlami pomerov jednotlivých zložiek (podvln) a teda majú vyššiu výpočtovú náročnosť. Druhým problémom

bol výskyt týchto vzorov v použitých dátach, ktorý je v porovnaní s impulznými vlnami nižší. To následne prezentuje problém pri tréningu, kedy v sieti vzniká pozitívny bias k triedam, resp. vzorom, ktoré majú početnejšie zastúpenie v tréningovej sade dát. Preto sa autor rozhodol rozlišovať iba tri vzory - stúpajúci impulz, klesajúci impulz, a ostatné vzory budeme považovať za korekcie. Toto zjednodušenie dovoľuje zvýšiť veľkosť datasetu pre každú klasifikovanú triedu, ako aj zvýrazniť rozdiely medzi týmito triedami na ich scalogramoch. Nízke rozdiely medzi scalogramami jednotlivých tried vznikajú hlavne z rigidnej definície impulzu v Elliottovej vlnovej teórii, kde dve vlny, medzi ktorými je koeficientami je 1% rozdiel môžu patriť do iných tried. Bližšie priblíženie spôsobu prípravy dát je poskytnuté v podsekcii 10.1.2.

## Scalogramy

Ako sme spomínali, pre tréning siete je potrebný dostatočný objem označených tréningových dát. Považoval som za vhodné tento dataset vygenerovať sám, nakoľko som nenašiel dostatočne veľký vhodný dataset. Scalogramy generujem s pomocou balíčkov PyWavelet, matplotlib a AlphaVantage programovacieho jazyka Python z dát sťahovaných cez rozhranie AlphaVantage API[10]. Generované scalogramy zobrazujú na ose y samotnú škálu signálu, na ose x čas a intenzita farby ilustruje koeficienty vypočítané spojitou vlnkovou transformáciou. Pri vlnkovej transformácii ponúka balíček PyWavelet na spojitú vlnkovú transformáciu, medzi inými aj vlnky Mexican hat, Morletovu, Gaussove a Shannonove vlnky. Pre účely generovania scalogramov som použili práve Morletovu vlnku,




Obrázek 10.1: Graf Morletovej vlnky, Zdroj: Autor.


ktorá je najviac podobná analyzovanému signálu kurzu akcie a teda poskytuje najlepšiu aproximáciu signálu pri rozložení na koeficienty.

Následne uvádzam iba pár príkladov scalogramov a im prislúchajúce grafy postupnosti bodov, resp. cien akcií, či mnou identifikovaných vzorov Elliotových vln.






Obrázek 10.2: Graf klesajúceho impulzu a jeho scalogram z dát spoločnosti Tesla




Obrázek 10.3: Graf impulzu a jeho scalogram z dát spoločnosti Apple, Zdroj: Autor




Obrázek 10.4: Graf korekcie a jeho scalogram z dát spoločnosti Apple, Zdroj: Autor

Môžeme z uvedených scalogramov pozorovať, že voľným okom môže byť problém rozdiely medzi vzormi identifikovať. Neurónová sieť však vďaka aplikovaniu mnohých filtrov a


extrakcii najcharakteristickejších rysov zo scalogramov tréningového datasetu by mala byť viac než schopná tieto triedy od seba oddeliť a aj ich klasifikovať na dopredu neznámych príkladoch. Aby sme lepšie ilustrovali rozdiely medzi jednotlivými triedami uvádzame obrázky vygenerované aplikáciou funkcie bitového XOR na horeuvedené scalogramy.



Obrázek 10.5: XOR impulz, korekcia, Zdroj: Autor



Obrázek 10.6: XOR korekcia, klesajúci impulz, Zdroj: Autor



Obrázek 10.7: XOR impulz a klesajúci impulz, Zdroj: Autor


Môžeme vidieť, že medzi scalogramami impulzov a korekcie je veľký rozdiel, znázorňený výraznými farbami, ktoré ilustrujú rozdiel farieb medzi danými scalogramami. Ako vidíme, scalogram klesajúceho impulzu nie je až natoľko rozdielny od scalogramu rastúceho impulzu, avšak predsa je na niekoľkých miestach výrazný rozdiel (svetlo zelená farba). Na základe práve týchto zobrazených rozdielov učím konvolučnú neurónovú sieť rozpoznávať jednotlivé vzory.

### Architektúra navrhnutého systému

Navrhnutý systém sa skladá z dvoch častí - rozpoznávacej a predikčnej. Rozpoznávacia časť je tvorená konvolučnou neurónovou sieťou, ktorá rozpoznáva vzory z Elliottovej vlnovej teórie na základe scalogramov vygenerovaných spojitou vlnkovou transformáciou vzorov z historickej časovej rady vybraných akcií. Výstup siete je následne vkladáný do predikčnej časti, tvorenej expertnými pravidlami založenými na Elliottovej teórii. Architektúra je inšpirovaná článkom [25], kde výsledky klasifikácie vzorov spracúva ďalšia neurónová sieť, avšak namiesto druhej, predikčnej neurónovej siete sme sa rozhodli iba pre implementáciu pravidiel vo forme tabuľky, nakoľko v rámci tejto diplomovej práce rozpoznávame menej vzorov. Logika predikcií je prezentovaná v tabuľke 10.1. Pri rozpoznaní stúpajúceho impulzu očakávam podľa Elliottovej teórie, že bude nasledovať korekcia v opačnom smere, teda dôjde k poklesu kurzu - to je pre systém signálom na predaj s cieľom realizácie kapitálového zisku. K opačnému prípadu príde pri rozpoznaní klesajúceho impulzu, vtedy očakávam korekciu spôsobujúcu stúpnutie ceny a teda je pre systém signálom na nákup. Ak systém nerozpozna jasný impulzný signál, tak bude uvažovať o aktuálnom kurze akcie, ako o kurze v priebehu korekcie, a radšej nebude generovať ani predajné ani nákupné signály, aby minimalizoval riziko kapitálovej straty.

Tabulka 10.1: Tabulka pravidiel generovania predikcií, Zdroj: Autor.

Vzor	Predikcia
Stúpajúci impulz	Sell
Klesajúci impulz	Buy
Korekcia	Hold



Obrázek 10.8: Reprezenácia navrhnutého systému tréningovania konvolučnej neurónovej siete, Zdroj: Autor.

### 10.1.2. Príprava dát

Dáta použité na tréningovanie siete sťahujem z portálu Alpha Vantage [10], ktorý poskytuje prístup k denným dátam o kurzoch akcií, forexu a kryptomien. Pre potreby tréningovania, testovania a validácie navrhnutej siete som stiahol maximálne dostupné historické dáta pre až dvadsaťjedna spoločností.

Tabulka 10.2: Východiskové dáta zo služby AlphaVantage, Zdroj: Autor.

Symbol	Dĺžka časovej rady	Symbol	Dĺžka časovej rady
AAPL	5336	JPM	5339
ADBE	5339	MSFT	5304
ACN	4446	MNST	5339
AMGN	5339	NFLX	4237
AMZN	5304	NVDA	5071
ATRI	5339	PG	5339
CSCO	5339	QCOM	5357
GTHX	465	TSLA	2195
JLL	5339	TXN	5357
JBT	2686	V	2772
:	:	VLO	5339

V predošlých sekciách som prezentoval rozpoznávané vzory - stúpajúci a klesajúci impulz, korekcia - pri príprave dát tieto vzory identifikujem v stiahnutých historických dátach, za účelom vygenerovania datasetu vhodného na učenie konvolučnej neurónovej siete. Sieť trénujem pomocou prístupu učenia s učiteľom a preto musí takýto dataset mať jednotlivé príklady vzorov roztriedené do samostatných priečinkov podľa rozpoznávaného vzoru. Generovanie datasetu prebieha v dvoch fázach - numerická identifikácia vzoru a následné prevedenie vzoru na scalogram.

---

**Algorithm 1** Algoritmus generovania datasetu, Zdroj: Autor.

---

```

data ← downloadAlphaVantageData(stockSymbols)
granularityLevels ← (1, 6, 30, 180)
patterns ← (impulse, fallImpulse, correction)
for symbol in data do
  for granularity in granularityLevels do
    impulses, fallImpulses, correctios ← identifyPattern(symbol,granularity)
  end for
  for item in (impulseList, fallImpulseList, correctionList) do
    scalogram ← continuousWaveletTransform(item, morletWavelet)
    saveImage(scalogram)
  end for
end for

```

---

Pri generovaní datasetu sú najprv stiahnuté historické dáta o kurze vybranej akcie z databáze Alpha Vantage, a následne sú v nich vyhľadávané definované vzory Elliottovej teórie na vybraných úrovniach granularity. Tie reprezentujú fraktálny charakter Elliotových vln. Následne z nich generujeme scalogramy, ktoré ukladáme. Spolu s ukladaním scalogramov sú ukladané aj indexy ich počiatku v danej časovej rade pre neskoršie potreby testovania. V názve scalogramu ukladám informácie, ktoré používame taktiež používam pri testovaní siete. Každý scalogram nesie v názve zakódovaný symbol príslušnej akcie a granularitu, na ktorej bol vygenerovaný.

## Numerická identifikácia vzoru

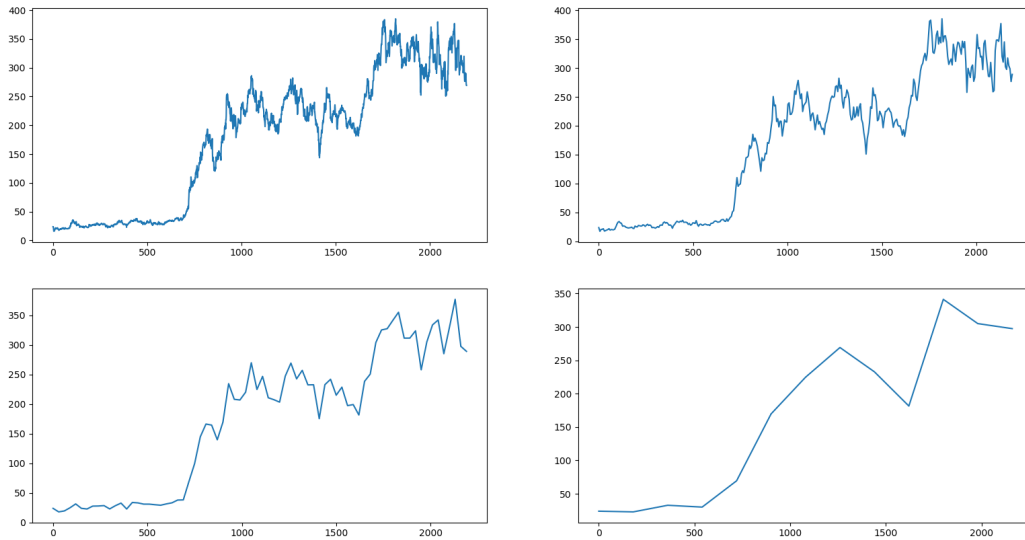
Identifikáciu vzorov robíme na základe pravidiel pre identifikovanie Elliottovho impulzu, ktoré sú v [19] nasledovne:

1. Vlna 2 nikdy nevstupuje do zóny vlny 1
2. Vlna 3 nikdy nie je najkratšia
3. Vlna 4 nikdy nevstupuje do zóny vlny 1, resp. žiadna časť vlny 4 nie je totožná s vlnou 2

Pre identifikáciu klesajúceho impulzu používame mierne upravené pravidlo 1:

1. Vlna 2 nikdy nevystupuje zo zóny vlny 1
2. Vlna 3 nikdy nie je najkratšia
3. Vlna 4 nikdy nevstupuje do zóny vlny 1, resp. žiadna časť vlny 4 nie je totožná s vlnou 2

Pre identifikáciu vzoru vyberáme z časových rád sekvencie šiestich hodnôt kurzu na konci dňa, teda tzv. close hodnoty. Na túto sekvenciu bodov následne aplikujem hore-uvadené pravidlá a rozhodnem, či sa jedná alebo nejedná o impulz. Identifikácia prebieha na rôznych úrovniach granularity - konkrétne na úrovniach 1, 6, 30 a 180. Tieto čísla vychádzajú z fraktálneho charakteru Elliottových vln, ktorý znamená, že každá Elliottova vlna môže byť zložená z vln nižšieho rádu. V tomto prípade predstavuje granularita 1 najnižší rád vln a granularita 180 najvyšší rád. Na úrovni granularity 1 teda vyberám šesť hneď po sebe idúcich hodnôt kurzu, na granularite 6 vyberám šesť hodnôt, tak že vyberám každú šiestu hodnotu, na vyšších úrovniach každú tridsiatu, resp. stoosemdesiatu hodnotu. Vzhľadom na dĺžky prístupných časových rád som považoval úrovne granularity nad 180 za príliš veľké, nakoľko by bol pravdepodobne identifikovaný malý počet vzorov. Identifikácia vzorov prebieha postupne zo získaných dát, ktoré sú postupne prehľadávané na jednotlivých úrovniach granularity. Tento prístup je časovo náročný, avšak z pohľadu získania kvalitného datasetu nutný. Pre malé urýchlenie identifikácie, ako aj snahu o zachovanie rovnováhy v triedach dát obmedzujeme generovanie korekcií, teda postupnosť hodnôt, ktoré nerozpoznáme ako impulz, na päťdesiat pre jednu úroveň granularity a jednu spoločnosť, resp. druh akcie. K hodnote päťdesiat sme prišli experimentálne počas procesu automatizácie generovania dát.



Obrázek 10.9: Graf zobrazujúci časovú radu kurzu akcií spoločnosti Tesla vo vybraných granularitách, Zdroj: Autor.

---

**Algorithm 2** Algoritmus identifikácie vybraných vzorov, Zdroj: Autor.

---

```

for  $y$  in  $data$  do
  counter  $\leftarrow$  1
  index  $\leftarrow$  index( $y$ )
  while  $index < index + 5 \times granularity$  do
    if  $counter \% 2 = 0$  then
      wave  $\leftarrow$   $\langle data[index]; data[index+granularity] \rangle$ 
      index  $\leftarrow$  index + granularity
    else
      wave  $\leftarrow$   $\langle data[index]; data[index+\text{ceil}(\frac{2}{3}granularity)] \rangle$ 
      index  $\leftarrow$  index +  $\text{ceil}(\frac{2}{3}granularity)$ 
    end if
  end while
  patternType  $\leftarrow$  identifyPattern(wave)
end for

```

---

Identifikácia vzorov prebieha postupným vyberaním postupností hodnôt kurzu vybranej akcie podľa zvolenej granularity. Pri vyšších granularitách musíme zohľadniť formát impulzov, ktoré sa majú spravidla formát 5-3-5-3-5, teda tri impulzy a dve korekcie. Vybrané granularity sú nastavené na dĺžku rozpoznávaných impulzov, teda počítajú s piatimi podvlnami. Nakoľko však podvlny-korekcie sa skladajú z len troch vln nižšieho rádu, tak pre podvlny 2 a 4 sledovaného impulzu skrátime ich rozsah na dve tretiny granularity, zaokrúhlenú na najbližšie väčšie celé číslo, aby sme dodržali formát impulzov. Následne vybranú postupnosť hodnôt kurzu, alebo kandidátnu vlnu, predáme do funkcie identifikácie nami definovaných vzorov Elliottových vln. Tá používa nasledujúci algoritmus.

Pri identifikácii vzorov používame už spomínané pravidlá pre identifikáciu impulzov z

---

**Algorithm 3** Algoritmus rozhodovania o type vzoru - identifyPattern(), Zdroj: Autor.

---

```
elasticity ← 0.90
if wave is rising then
  if wave3 < wave2 and wave3 > elasticity × wave1 then
    if length(wave3) > elasticity × length(wave1) or length(wave3) > elasticity × length(wave2) or length(wave3) > elasticity × length(wave4) or length(wave3) > elasticity × length(wave5) then
      if elasticity × wave4 < wave1 then
        return impulse
      end if
    end if
  end if
else if wave is falling then
  if wave3 > wave2 and wave3 > elasticity × wave1 then
    if length(wave3) > elasticity × length(wave1) or length(wave3) > elasticity × length(wave2) or length(wave3) > elasticity × length(wave4) or length(wave3) > elasticity × length(wave5) then
      if elasticity × wave4 > wave1 then
        return falling impulse
      end if
    end if
  end if
else
  return correction
end if
```

---

Elliottovej vlnovej teórie. S cieľom získania dostatočne rozsiahleho datasetu pre trénovanie siete sme pri numerickej identifikácii vzorov do algoritmu vložili koeficient elasticity, ktorý dovoľuje jemne upraviť pravidlá, do ktorých by mal spadať impulz podľa Elliottovej definície. Koeficient sme pri identifikácii vzorov nastavili na hodnotu 0.9, čo uvoľňuje pravidlá tak, aby bola pri identifikácii impulzu tolerancia  $1 - elasticity$ , teda 10%. To nám umožňuje vygenerovať rozsiahlejší dataset, ako označiť hraničné prípady za impulzy. Rozšírenie množiny akceptovaných vln ako impulzov síce nie je podľa Elliottovej definície, a tak znižuje istotu, že po impulze bude nasledovať korekcia, avšak pre sieť zlepšuje schopnosti rozpoznávania zväčšením tréningového datasetu, a zvýšením rozdielov medzi rozpoznávanými vzormi.

### Prevedenie na scalogram

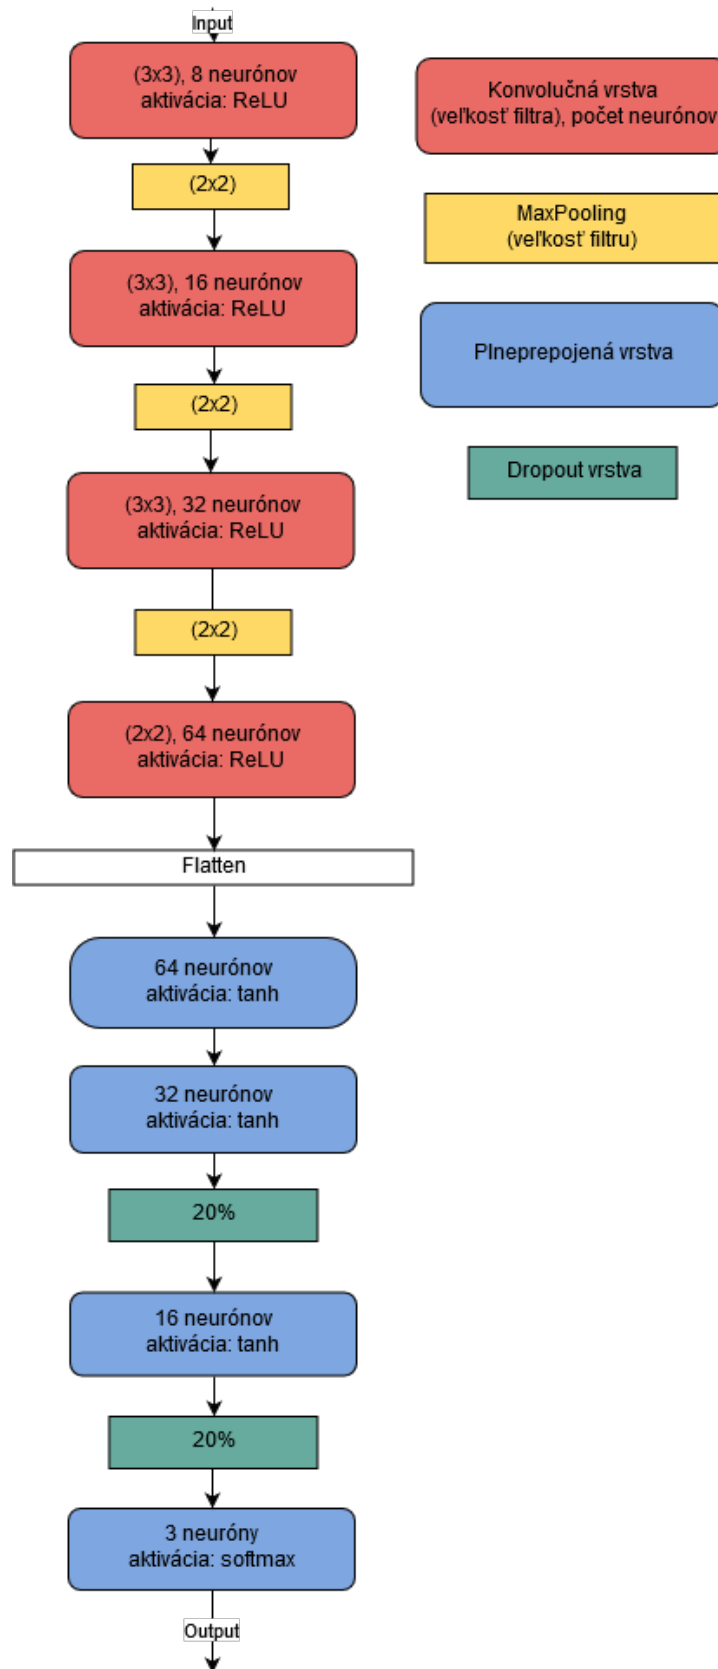
Počas identifikácie sú nájdené vzory automaticky prevedené do podoby scalogramu a uložené do príslušného priečinka svojej triedy. Scalogram je generovaný na základe postupnosti hodnôt, na ktoré je aplikovaná spojitá vlnková transformácia vlnkou Morlet Wavelet. Generujem scalogramy s rozlíšením  $6 \times 64$  bodov, kde 6 je dĺžka transformovaného vzoru, z ktorých odstránime osi a ich hodnoty, nakoľko tieto neobsahujú informácie,



ktoré by pomáhali sieti lepšie rozpoznávať jednotlivé vzory.

### 10.1.3. Architektúra a tréovanie siete

K výslednej architektúre použitej konvolučnej siete som prišiel postupným experimentovaním s množstvom konvolučných vrstiev a počtom v nich obsiahnutých neurónov. Výsledkom je sieť s piatimi vrstvami so vstupom v tvare  $32 \times 64 \times 3$ , teda obrázky v rozlíšení  $32 \times 64$  s tromi kanálmi farby RGB. Používam konvolučné vrstvy Conv2D s aktivačnou funkciou hyperbolického tangensu Tanh a so vzostupujúcim počtom neurónov - 8, 16, 32 a 64. V tých prebieha samotné rozpoznávanie vzorov Elliottových impulzov. Ďalej sú prítomné aj vrstvy MaxPooling, ktoré slúžia na extrakciu významných hodnôt z jednotlivých častí tréningových obrázkov. V sieti nasleduje vrstva Flatten, ktorá prevedie 3D výsledky z konvolučných vrstiev na 1D vektor. Potom sú zaradené tri plne prepojené vrstvy Dense s počtom neurónov 64, 32 a 16, používajúce aktiváciu funkciou hyperbolického tangensu tanh. Na konci je výstupnou vrstvou plne prepojená vrstva, ktorá má tri neuróny, každý reprezentujúci jeden rozpoznávaný vzor. Po všetkých plne prepojených vrstvách okrem výstupnej nasleduje tzv. Dropout, alebo vylúčenie niektorých tréningových krokov z ovplyvňovania váh v sieti s cieľom predísť pretrénovaniu (overfitting) siete. Plne prepojená vrstva používa aktivačnú funkciu softmax, ktorá normalizuje hodnotu do intervalu  $\langle 0,1 \rangle$ . Hodnoty neurónov potom predstavujú percentuálne ohodnotenie úrovne istoty siete, že sa jedná o vzor reprezentovaný daným neurónom.



Obrázek 10.10: Reprézentácia modelu použitej konvolučnej siete, Zdroj: Autor


Tabulka 10.3: Tabulka rozloženia dát, Zdroj: Autor.

Vzor	Tréning	Validácia	Testovanie	Spolu
Stúpajúci impulz	868	146	164	1178
Klesajúci impulz	925	132	162	1219
Korekcia	917	128	151	1196

## Tréning

Sieť trénujem na scalogramoch vygenerovaných spôsobom uvedeným v predošlej sekcii. Scalogramy sú vyberané z predpripravených priečinkov, sú prevedené do rozlíšenia  $32 \times 64$ , a vyberajú sa náhodne, aby sa zlepšili generalizačné schopnosti siete. Používam optimizátor Adaptive Subgradient method, alebo Adagrad predstavený v [5] s pôvodným nastavením learning rate na hodnotu 0.01. Trénovanie má nastavené maximálne trvanie 500 epoch a v každej epoche je sieť trénovaná na sto scalogramoch a validovaná na štyridsiatich. Vyšší počet epoch pri testovaní neprinesol markantné zvýšenie presnosti, ktoré by odpovedalo navýšeniu časovej náročnosti trénovania. S cieľom optimalizácie trénovania siete som teda následne aplikovali tzv. callback, ktorým sa automaticky monitorujú zmeny loss funkcie na tréningovom datasete. Callback trénovanie ukončí, keď sa hodnota loss funkcie celkovo nezníži po vybraný počet krát, nie nutne za sebou, v tomto prípade dvadsať.

Na grafoch môžeme vidieť, že funkcia loss pri tréningu viditeľne osciluje, čo bolo dôvodom



Obrázek 10.11: Vizualizácia presnosti a funkcie loss v priebehu trénovania, Zdroj: Autor.


pre pomerne vysoké nastavenie tolerancie callbacku na až dvadsať prípadov kedy sa loss nezlepší. Pri nižšom nastavení by totiž mohlo prísť k predčasnému zastaveniu tréningu kvôli zákmitu, aj keď by v ďalších epochách mohol pokračovať trend znižovania loss funkcie, čiže zlepšovania rozpoznávacích schopností siete.

Sieť sme trénovali na datasete 2710 tréningových, 406 validačných scalogramov.

### 10.1.4. Výsledky

Po natrénovaní siete na tréningových a validačných scalogramoch som na zhodnotenie jej presnosti použil 477 testovacích scalogramov, ktoré sieti pri trénovaní neboli predstavené.

Išlo o scalogramy z rovnakého datasetu, avšak vybraných a oddelených pred trénovaním. Tréningový dataset obsahuje scalogramy z dátových rád všetkých použitých spoločností vo všetkých úrovniach granularity. Vyhodnotenie úspešnosti predikcií nám poskytne informácie o presnosti rozpoznávania klesajúcich a rastúcich impulzov, a korekcií, ako boli definované v predošlých sekciách. Na zhodnotenie používame maticu zámen, a hodnoty precision, recall a F1-score, podľa ich definície v podsekcii 4.3.6.



Obrázek 10.12: Matica zámen trénovej navrhnutej konvolučnej siete, Zdroj: Autor

Na matici zámen môžeme vidieť, že sieť vo výraznej väčšine prípadov správne rozpoznala vzor na testovacích scalogramoch. Najviac dochádzalo k zlému rozpoznaniu korekcií, v matici nazvanými NoWave, kedy dochádzalo k zámene za stúpajúce impulzy (Impulse) - 77-krát a klesajúce impulzy (FallImpulse) - 88-krát. K zámene typov impulzov nedošlo vôbec, čo je z hľadiska fungovania siete veľmi dobré, nakoľko správne rozpoznávanie impulzov je z technologického pohľadu pre použiteľnosť siete v reálnom svete najdôležitejším ukazovateľom. Pri rozpoznávaní impulzov došlo k zámene za korekciu iba 10-krát pre klesajúci impulz a iba 32-krát pre stúpajúci impulz.

Tabuľka potvrdzuje závery z matice zámen. Rozpoznávanie klesajúceho impulzu má najnižšiu hodnotu presnosti - 82%, nakoľko prišlo k jeho nesprávnemu rozpoznaniu percentuálne najviac krát - sieť celkovo označila 488 scalogramov, avšak iba 400 bolo klesajúcimi impulzmi, z toho 88-krát išlo o korekciu označenú za klesajúci impulz a 10-krát o klesajúci impulz označený nesprávne ako korekcia. Avšak schopnosť siete správne rozpoznať klesajúci impulz je až 97%, teda ak scalogram predstavoval stúpajúci impulz, tak ho sieť správne označila v 97% prípadov. Pri stúpajúcom impulze bola presnosť rozpoznávania 93%, a taktiež ak na scalograme bol stúpajúci impulz, tak sieť klasifikovala správne v

Tabulka 10.4: Tabulka hodnôt precision, recall a F1-score navrhutej konvolučnej siete, Zdroj: Autor.

Vzor	Precision	Recall	F1-score	Počet
Klesajúci impulz	0.82	0.97	0.89	400
Stúpajúci impulz	0.93	0.97	0.95	1004
Korekcia	0.93	0.78	0.85	746
Mikro priemer	0.90	0.90	0.90	2150
Makro priemer	0.89	0.91	0.89	2150
Vážený priemer	0.91	0.90	0.90	2150

97% prípadov. Korekcie mali taktiež 93%-tnú presnosť, avšak schopnosť siete správne rozpoznať scalogram korekcie ako korekciu bola horšia - 78%. Všeobecne však môžeme povedať, že s váženým priemerom presnosti až 91% je sieť veľmi dobrá v rozpoznávaní nami limitovaného počtu vzorov Elliottovej vlnovej teórie, a vzniká tak predpoklad na jej ziskovosť v reálnych podmienkach obchodovania akcií na burze. Bližšie sa pokúsím priblížiť úspešnosť siete na burze v simulovaných podmienkach v nasledujúcej kapitole.

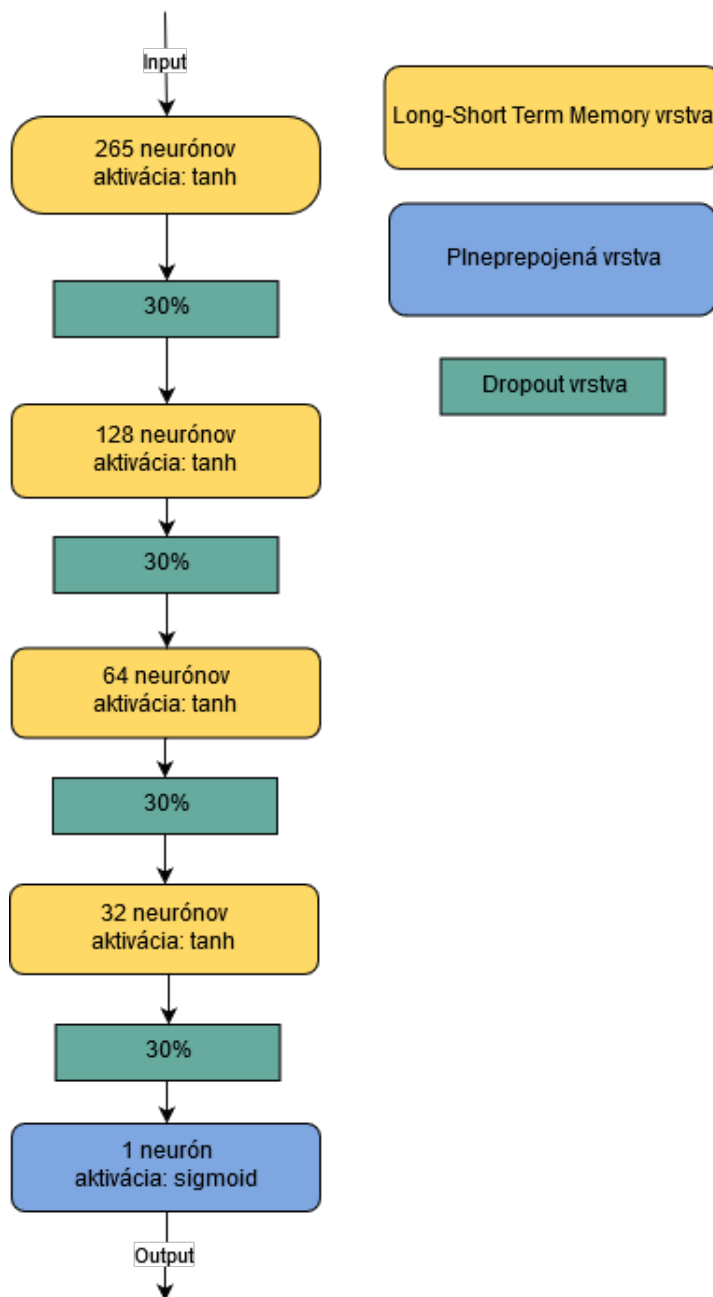
## 10.2. Sieť typu Long Short Term Memory

V tejto sekcii je uvedený návrh a implementácia rekurentnej siete typu Long-Short Term Memory, slúžiacej na porovnanie úspešnosť si navrhnutým systémom rozpoznávania vzorov Elliottovej vlnovej teórie založenom na konvolučnej neurónovej sieti.

### 10.2.1. Architektúra siete

Pre účel porovnania s navrhnutou CNN som považoval za dostačujúce navrhnuť pomerne jednoduchú LSTM sieť s piatimi vrstvami. Sieť má jednu vstupnú vrstvu typu LSTM, ktorá očakáva dáta v tvare 1 vzorka, ktorá obsahuje 50 hodnôt s 26 prediktormi. Hodnota 50 slúži na predanie informácie o množstve predošlých vstupov, ktoré má sieť uvažovať pri tréňovaní na aktuálnom vstupe. Rozsah tohto posuvného okna som zvolil po pretestovaní viacerých možností od 30 (simulujúce dĺžku jedného mesiaca) až po 100. Okno s veľkosťou 50 bolo dobrým kompromisom medzi zvýšením objemu informácií, na ktorých sa sieť učí a z toho plynúcim nárastom zložitosti a dĺžky tréningu siete. Sieť má štyri skryté vrstvy typu LSTM s 256, 128, 64 a 32 neurónmi. K počtu neurónov a vrstiev som došiel postupným experimentovaním. Výstupnou vrstvou je jedna plne prepojená vrstva (v použitých balíčkoch jazyka Python nazývaná aj Dense) s jedným neurónom, ktorej aktivačnou funkciou je sigmoid. Tá spôsobí transformáciu informácií z vyšších vrstiev na hodnotu 0 alebo 1 v neuróne výstupnej vrstvy, teda informáciu ktorú môžeme interpretovať ako klesajúci alebo rastúci trend. Sieť používa upravené vrstvy typu LSTM zvané CuDNNLSTM, ktoré sú implementáciou vrstvy LSTM s možnosťou tréňovania na GPU.<sup>1</sup>

<sup>1</sup><https://keras.io/layers/recurrent/>




Obrázek 10.13: Reprézentácia vrstiev modelu, Zdroj: Autor.

### 10.2.2. Dáta a tréning

Sieť je trénovaná na historických dátach o kurze a obchodovanom objeme akcie 'AMZN' spoločnosti Amazon, spolu s vypočítanými indikátormi technickej analýzy pre túto istú akciu. Používam indikátory Bollingerove pásy, Relative Strength Index, stochastický oscilátor, MACD, jednoduchý kľzavý priemer, Rate of Change, Parabolic SAR, Commodity Channel Index (CCI), On Balance Volume (OBV) a Midprice. Použité sú historické dáta od dátumu 2.1.1998, teda spolu 5303 hodnôt, na ktorých sledujem denné informácie o kurze - open, high, low, close ako aj spomínaný obchodovaný objem. Dáta sú stiahnuté z portálu Alpha Vantage, cez nimi poskytované API[10]. Trénovanie prebieha s nastaveným

tzv. early stopping alebo skorým zastavením, ktoré zastaví tréning v prípade, kedy sa hodnota loss funkcie na validačnom datasete za určitý počet epoch nezlepší. Trénovanie je nastavené na sto epoch so skorým zastavením s toleranciou 10 zhoršení. Ako loss funkcia je nastavená binárna crossentropia, ktorá je štandardnou funkciou pre klasifikáciu s dvoma triedami, ako je tomu aj v prípade tejto siete. Za optimizátor som zvolil RMSProp s learning rate nastaveným na 0.00075. Sledovanou metrikou je presnosť klasifikácie. Dve tretiny dát sú oddelené na tréningovanie a jedna tretina na testovanie. Z tréningových dát je ešte 15% vyhradených na validáciu pri tréningu.




Obrázek 10.14: Vizualizácia presnosti a funkcie loss v priebehu tréningovania, Zdroj: Autor

### 10.2.3. Presnosť a úspešnosť predikcií

Nakolko som predikciu trendu sieťou LSTM pojal ako klasifikačný problém, tak som na zhodnotenie jej presnosti použil maticu zámien.

Tabulka 10.5: Tabulka hodnôt precision, recall a F1-score trénovanej LSTM neurónovej siete, Zdroj: Autor.

Vzor	Precision	Recall	F1-score	Počet
Zvýšenie kurzu	0.98	0.92	0.95	583
Pokles kurzu	0.94	0.99	0.96	705
mikro priemer	0.96	0.96	0.96	1288
makro priemer	0.96	0.96	0.96	1288
vážený priemer	0.96	0.96	0.96	1288



Obrázek 10.15: Matica zámien implementovanej siete typu LSTM, Zdroj: Autor.

Na priloženej matici zámien môžeme vidieť, že po ukončení tréovania dosahuje sieť na testovacích dátach veľmi dobrú úspešnosť. Môžeme teda skonštatovať, že presnosť siete je veľmi vysoká. K zámene stúpania za pokles došlo 29-krát a k opačnej chybe 49-krát. Bližší pohľad na výsledky nám ponúka nasledujúca tabuľka. V tabuľke môžeme pozorovať, že sieť správne predpovedala 99% poklesov a 92% nárastov kurzu. Celkovo môžeme hovoriť až o 96%-tnej presnosti predikcií.

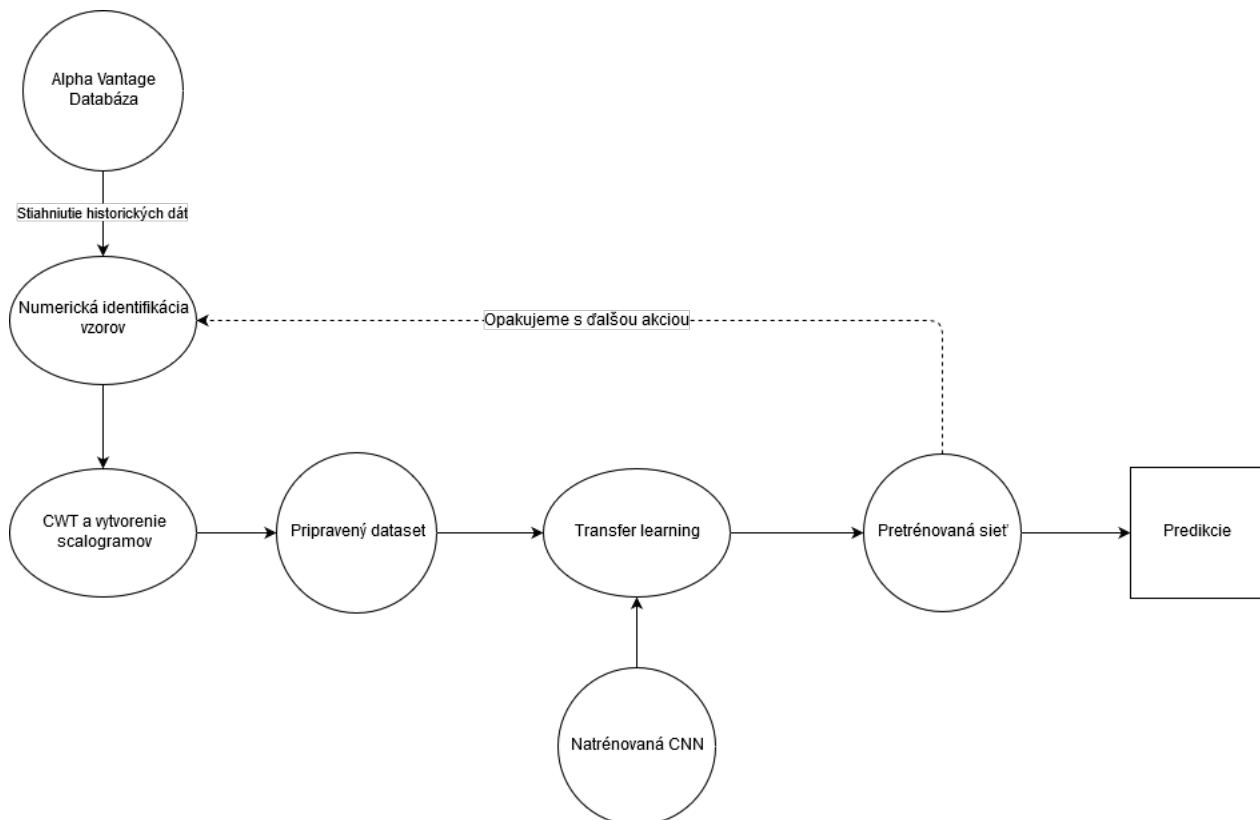


# 11. Testovanie

V tejto kapitole podrobíme obe navrhnuté siete podrobnejším testom, ktoré budú simulovať praktické použitie v reálnych podmienkach. Sledovať budeme presnosť predpovedí, ako aj profitabilitu sietí na vybraných datasetoch.

## 11.1. Metodológia testovania

Pre lepšie zhodnotenie využiteľnosti navrhnutých sietí v reálnom svete budeme testovať, ako dobre sa vysoká presnosť pri tréningu preniesie do výkonu sietí, keď budeme simulovať ich profitabilitu na dátach spoločností, na ktorých boli siete tréňované. Navyše budeme skúmať aj prenositeľnosť, respektíve schopnosť generalizácie, sietí hodnotením ich presnosti a profitability na dátach kurzov akcií spoločností, ktoré neboli súčasťou tréningového datasetu. Sieť budeme testovať na piatich datasetoch známych z testovania a piatich datasetoch, s ktorými sa sieť predtým nestretla. Pri testovaní budú obe siete pretrénované na použitie s testovaným datasetom. Sieť LSTM bude pretrénovaná kompletne a pri pretrénovaní konvolučnej siete bude aplikovaná metóda transfer learning a teda budú pretrénované iba jej plne prepojené vrstvy.



Obrázok 11.1: Schéma testovacieho procesu, Zdroj: Autor

### 11.1.1. Metodológia simulácie profitability

Profitabilitu sietí hodnotíme na základe short obchodov na kapitálovom trhu s iba jednou, vybranou akciou. Na vyhodnotenie použijeme dataset historických dát vybraných akcií a budeme počítat profitabilitu na základe rozhodnutia sietí a rozdielov kurzu akcií.

#### Pre sieť typu LSTM

Sieť typu LSTM je navrhnutá na predikciu trendu v deň nasledujúci po dátach na vstupe siete. Z toho dôvodu budeme jej profitabilitu merať ako rozdiel medzi hodnotou kurzu pri závierke burzy v deň vstupných dát a hodnoty kurzu pri závierke burzy v nasledujúci deň, vynásobený počtom akcií, ktoré by sme mohli nakúpiť za určený počet finančných prostriedkov. Následne po každej predikcii odpočítame pevne daný poplatok, ktorý simuluje poplatok platený brokerovi na burze za vykonanie obchodu.

#### Pre konvolučnú sieť

Pri konvolučnej sieti používam obdobný prístup ako pri hodnotení profitability LSTM siete, avšak mierne skomplikovaný prístupom používania nami vybraných vzorov Elliottových vln. Predikcie tejto siete rozpoznávajú impulzy, po ktorých podľa Elliottovej teórie nasledujú korekcie s opačným trendom. Preto som zvolil obchodovaciú stratégiu, kedy neporovnávam kurzy vybranej akcie nutne v dvoch po sebe idúcich dňoch. Za lepšiu považujem spôsob počkať 3 časové úseky dané granularitou vstupných dát, aby som počkal na rozvinutie korekcie. Teda pri granularite 1 budem sledovať zmenu medzi hodnotami dvoch po sebe idúcich dní, pri granularite 6 budem sledovať rozdiel medzi hodnotami v deň predikcie a o 5 dní neskôr, a analogicky aj pre vyššie úrovne granularity. Tiež prichádza do hry rozdiel medzi rozpoznaním stúpajúceho a klesajúceho impulzu:

- Pri stúpajúcom impulze očakávame podľa Elliottovej teórie následný pokles kurzu, takže pri short obchode si na predaj požičiam akcie od brokera, predám ich za cenu close daného dňa, a následne ich musím vrátiť. Akcie vraciam po rozvinutí korekcie a poklese ceny, za hodnotu open dňa posunutého o hodnotu granularity. Teda výpočet je:

$$profit = close[x] - open[x + granularita]$$

- Pri klesajúcom impulze očakávam naopak rast kurzu, takže jednoducho nakúpim akcie za cenu close dňa predikcie a následne simulujem ich predaj za kurz open, ale opäť dňa posunutého o hodnotu granularity. Teda hodnota profitu je:

$$profit = open[x + granularita] - close[x]$$

Profit každého obchodu je taktiež násobený počtom akcií, ktoré za vybranú hodnotu finančných prostriedkov vieme kúpiť. Podobne ako pri simulovaní obchodov siete LSTM aj tu po každom obchode odpočítam pevnú čiastku simulujúcu poplatok za služby brokera.

## 11.2. Testovacie dáta

Dátové rady, resp. akcie na testovanie som vyberal na základe ich kurzu a hodnoty Hurstovho exponentu. Spravil som tak so zámerom preskúmať závislosť presnosti navrhnutých

sietí práve od kurzu akcie a ich volatility meranej Hurstovým exponentom. Pri pretrénovaní siete som rozdelil scalogramy týchto datasetov vždy tak, aby bola sieť trébovaná na dvadsať scalogramoch každého vzoru a validovaná na šiestich. Zvyšné scalogramy boli použité na testovanie. Následne v tejto sekcii uvádzam grafy profitability a príslušné matice zámen pre trébovanie na všetkých úrovniach granularity.

Tabulka 11.1: Tabulka testovacích datasetov, Zdroj: Autor.


Symbol	Hurstov exponent	Kurz z 5.5.2019
AAPL	0.9154	211.75
AMD	0.9647	28.22
AMZN	0.99	1962.46
CSCO	0.8104	54.94
CTXS	0.8862	99.15
EA	0.7578	92.50
INTU	0.6834	248.86
MSFT	0.7590	128.90
NVDA	0.8967	183.01
SYMC	0.6761	23.15
TXN	0.7856	117.47

## 11.3. Testovanie

### 11.3.1. Sieť typu Long-Short Term Memory


Pretrénovanie siete LSTM je časovo náročné, preto som zvolil testovanie iba na troch datasetoch - akciách AMZN, na ktorých bola sieť trébovaná pôvodne, a po pretrénovaní siete aj na akciách MSFT a CSCO. Tieto tri časové rady, som vybral na základe ich odlišnosti v hodnote Hurstovho exponentu a približnej entropie, ale aj rozdielmi v kurze ich akcií - CSCO \$54.94, MSFT \$128.90 a AMZN \$1962.46<sup>1</sup>.

<sup>1</sup>Hodnoty z 3.5.2019, zdroj: [www.finance.yahoo.com](http://www.finance.yahoo.com)

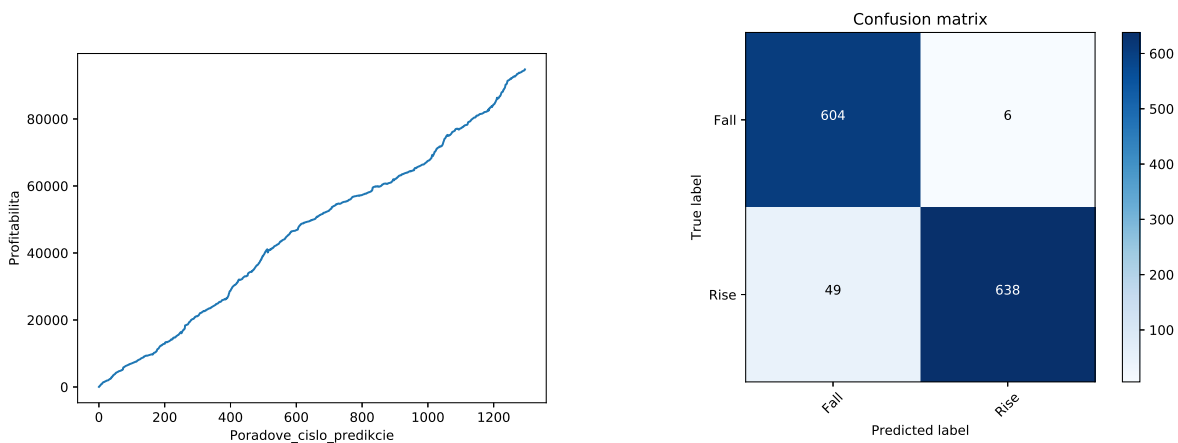


Obrázek 11.2: Profitabilita siete pri obchodovaní akcií AMZN a príslušná matica zámien, Zdroj: Autor.

Z testu vidíme, že siete sa darilo správne predpovedať smer trendu, presnosť, ako sme ukázali v kapitole o implementácii LSTM siete, dosiahla až 96%. Z toho vychádza aj takmer lineárne stúpajúci profit. Po priblížení môžeme vidieť aj malé poklesy profitu.

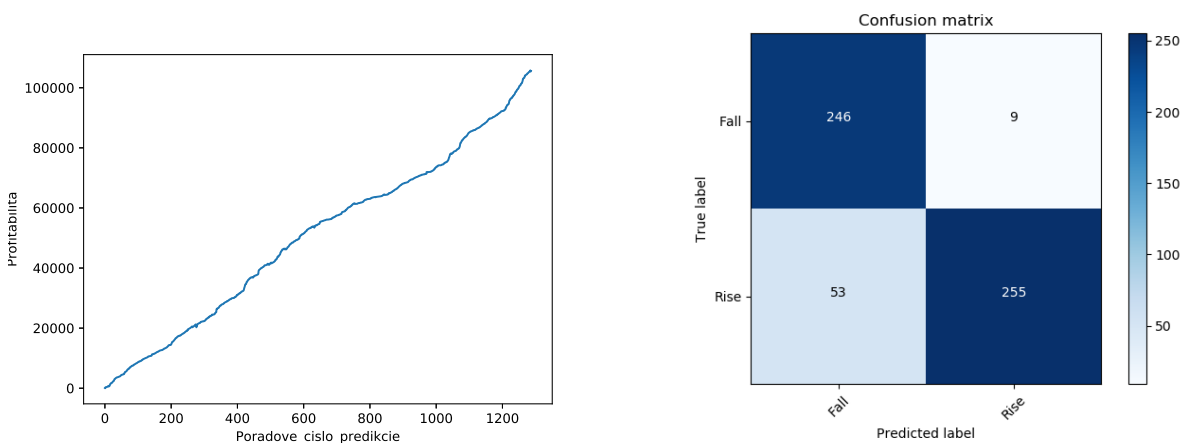


Obrázek 11.3: Detail profitability siete, akcie AMZN, Zdroj: Autor.



Obrázek 11.4: Profitabilita siete pri obchodovaní akcií CSCO a príslušná matica zámien, Zdroj: Autor.

Podobne ako pri teste s akciami AMZN aj tu jednoduchá LSTM sieť dosahuje veľmi vysokú presnosť predpovedí. Rast profitu je o niečo pomalší, avšak to je pochopiteľné vzhľadom na veľký rozdiel medzi kurzom akcií CSCO a AMZN.



Obrázek 11.5: Profitabilita siete pri obchodovaní akcií MSFT a príslušná matica zámien, Zdroj: Autor.

Aj do tretice sieť preukázala vysokú presnosť a schopnosť v takto simulovaných podmienkach s jednoduchou obchodovacíou stratégiou dosiahnuť profit. Krivka profitu opäť rastie približne lineárne, takže môžeme konštatovať, že sieť zarába takmer na každom obchode.


V testoch sa LSTM siete darilo veľmi dobre, čo je koniec koncov podľa očakávaní vzhľadom na jej dobre preskúmané a preukázané schopnosti v tejto oblasti. Z tohto dôvodu považujem použitie tejto siete na porovnanie s novým prístupom navrhnutým v tejto práci za správne.

### 11.3.2. Konvolučná neurónová sieť na Elliottovej teórii

Pri testovaní CNN som testy rozdelil na dve časti, jedna obsahujúca testovanie s datasetmi, na ktorých bola sieť trébovaná, a druhá kde sieť pretrébojeme na malom datasete vygenerovaným z akcií, s ktorými sa sieť pri učení nestretla.

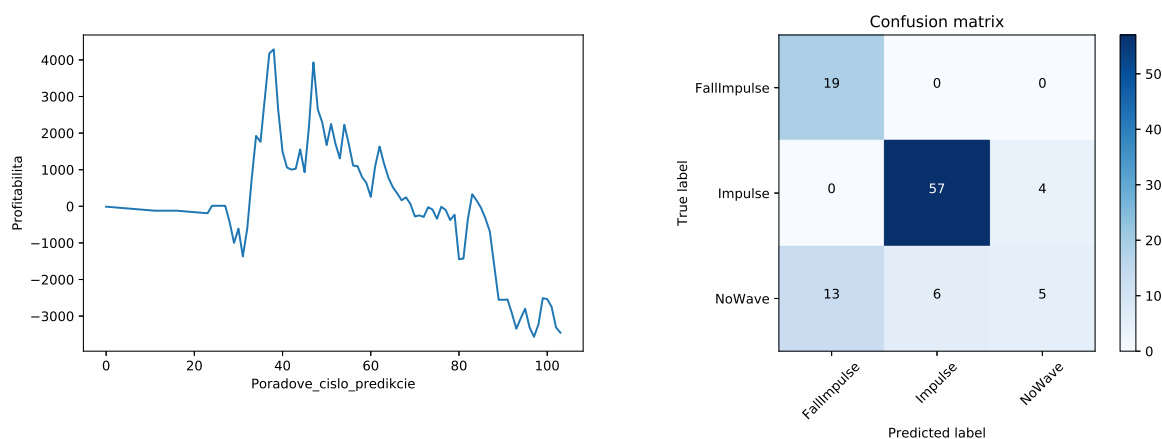
#### Na trébovaných dátových radách

Za účelom testovania som vybral akcie TXN, AAPL, CSCO, NVDA a MSFT. Nie všetky akcie obsahovali na granularite 180 dostatok dát na sformovanie trébovacieho aj testovacieho datasetu, preto pri nich nie sú uvedené výsledky pre túto granularitu.




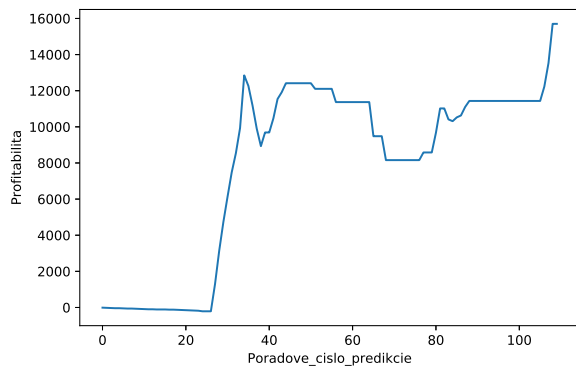
Obrázek 11.6: Profitabilita siete pri obchodovaní akcií TXN, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Sieť ukazuje dobrý výsledok, je v plusových číslach, a aj presnosť rozpoznania je dobrá.





Obrázek 11.7: Profitabilita siete pri obchodovaní akcií TXN, granularita 6 a príslušná matica zámen, Zdroj: Autor.

V tomto prípade môžeme pozorovať, že zle rozpoznané korekcie, ktoré sieť označila za klesajúci impulz, spôsobili vo výsledku stratu.




Obrázek 11.8: Profitabilita siete pri obchodovaní akcií TXN, granularita 30 a príslušná matica zámen, Zdroj: Autor.

Na matici zámen je zjavná chybovosť rozpoznania vzorov, avšak napriek tomu sieť dosiahla profitu. Zamenenie impulzov za korekcie nespôsobilo stratu vďaka vhodnej stratégii odloženia obchodovania pri rozpoznaní korekcie a čakaní na jasnejší impulz. Napriek profitu však treba konštatovať, že v tomto prípade si sieť veľmi dobre nevedla.




Obrázek 11.9: Profitabilita siete pri obchodovaní akcií MSFT, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Opäť môžeme pozorovať menej ako ideálnu presnosť rozpoznávania, hlavne pri korekciách. Podobne ako v predošlom prípade pri akciách TXN však sieť dosiahla kladnej profitability.



Obrázek 11.10: Profitabilita siete pri obchodovaní akcií MSFT, granularita 6 a príslušná matica zámen, Zdroj: Autor.


V kontraste s testom na granularite 1, na granularite 6 sieť bola veľmi presná pri rozpoznávaní, ale vývoj profitu bol turbulentný, aj keď nakoniec sieť dosiahla kladného výsledku.



Obrázek 11.11: Profitabilita siete pri obchodovaní akcií MSFT, granularita 30 a príslušná matica zámen, Zdroj: Autor.


Na granularite 30 vidno, že zámena niektorých korekcií za impulzy pri rozpoznávaní opäť spôsobila po slubnom vývoji na začiatku pád profitu a vo výsledku stratu.







Obrázek 11.12: Profitabilita siete pri obchodovaní akcií MSFT, granularita 180 a príslušná matica zámen, Zdroj: Autor.

Na tejto granularite vidíme znovu sľubný nástup, ale následne príde k prudkému poklesu profitu aj napriek pomerne vysokej presnosti rozpoznávania. Sieť nakoniec dosiahne profit, ale vzhľadom na dĺžku časového úseku po ktorý by tieto simulované obchody trvali nie je profit veľmi dobrý.




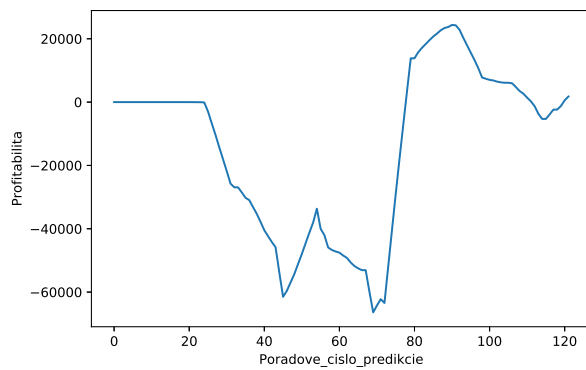
Obrázek 11.13: Profitabilita siete pri obchodovaní akcií AAPL, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Pri teste s akciami AAPL na najnižšej granularite mala sieť iba priemernú presnosť a môžeme vidieť, že nepresnosti v rozpoznávaní spôsobili prepád do záporných čísel, odkiaľ sa už sieti nepodarilo zotaviť.





Obrázek 11.14: Profitabilita siete pri obchodovaní akcií AAPL, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Napriek dobrej presnosti, iba šiestim chybám, je na granularite 6 s akciami AAPL sieť výrazne stratová.





Obrázek 11.15: Profitabilita siete pri obchodovaní akcií AAPL, granularita 30 a príslušná matica zámen, Zdroj: Autor.

Môžeme konštatovať vysokú presnosť rozpoznávania, no opäť napriek tomu je sieť po väčšinu času stratová a nakoniec skončí v kladných číslach, no iba tesne nad nulou.




Obrázek 11.16: Profitabilita siete pri obchodovaní akcií CSCO, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Sieť si znovu viedla dobre, z oboch hľadísk - vysoká presnosť aj kladná profitabilita.




Obrázek 11.17: Profitabilita siete pri obchodovaní akcií CSCO, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Podobne ako na nižšej granularite pri obchodovaní s akciami CSCO, aj tu sieť ukazuje dobrý výsledok.





Obrázek 11.18: Profitabilita siete pri obchodovaní akcií CSCO, granularita 30 a príslušná matica zámien, Zdroj: Autor.

Ako aj pri niektorých predošlých testoch vidíme 100%-tnú presnosť, avšak sieť značne prerobí. To indikuje nedostatky buď v zvolenej stratégii obchodov, ale v koncepte siete, nakoľko pri bezchybnom rozpoznaní scalogramov a aplikovaní Elliottovej teórie by sieť teoreticky mala dosiahnuť vysokého zisku.





Obrázek 11.19: Profitabilita siete pri obchodovaní akcií NVDA, granularita 1 a príslušná matica zámien, Zdroj: Autor.

Aj pri obchode s akciami NVDA pozorujeme jav, kedy je sieť napriek vysokej presnosti stratová. Vzhľadom na charakter kapitálových trhov je kolísavosť výsledkov na menšom datasete do určitej miery pochopiteľná, no stále nežiadúca.



Obrázek 11.20: Profitabilita siete pri obchodovaní akcií NVDA, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Na vyššej úrovni granularity si môžeme všimnúť chyby v rozpoznávaní, v ktorých ide znova zväčša o zámenu impulzu za korekciu. Podobne ako v teste s akciami MSFT na granularite 1 vďaka vhodne navrhnutej tabuľke interpretácie vzorov, kedy som zvolil po rozpoznaní korekcie signál HOLD, predíde stratám.




Obrázek 11.21: Profitabilita siete pri obchodovaní akcií NVDA, granularita 30 a príslušná matica zámen, Zdroj: Autor.

V tomto prípade sieť spravila chyby pri rozpoznávaní nielen zámenu impulzu za korekciu, ale aj opačne. V tých momentoch teda došlo k nesprávnemu vygenerovaniu signálov SELL, ktorých výsledkom bola kapitálová strata.

### Na netréovaných dátových radách


Na testovanie sme použili akcie spoločností Electronic Arts, Inc. (EA) a AMD, ktoré neboli použité pri trénovaní navrhnutej siete, a ktoré sme vybrali pre ich odlišné hodnoty Hurstovho exponentu. Časová rada kurzu akcie EA má hodnotu Hurstovho exponentu  $H = 0.7578$  a teda môžeme konštatovať, že je menej náhodná. Na druhej strane časová

rada pre akciu AMD má hodnotu Hurstovho exponentu  $H = 0.9647$ , čo indikuje väčšiu náhodnosť, resp. variabilitu.





Obrázek 11.22: Profitabilita siete pri obchodovaní akcií EA, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Na matici zámen môžeme vidieť, že schopnosť rozpoznania vzorov sa po využití transfer learningu pomerne úspešne preniesol aj na rozpoznávanie v predtým neznámej časovej rade. Graf profitability ukazuje stagnáciu na začiatku, kedy sieť rozpoznala iba niekoľko korekcií, avšak následne pozorujeme zdravý nárast profitu, ktorý napriek chybám okolo príkladu 25 skončí na úrovni +\$3000, čo je vzhľadom na vstupný kapitál 30% profit.





Obrázek 11.23: Profitabilita siete pri obchodovaní akcií EA, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Matica zámen opäť ukazuje vysokú mieru správnosti predikcií, avšak na grafe profitability môžeme vidieť, že sieti by sa v tomto prípade až dobre nedarilo a napriek dobrému profitu zhruba v polovici sledovaného datasetu, by sieť skončila v strate.




Obrázek 11.24: Profitabilita siete pri obchodovaní akcií EA, granularita 30 a príslušná matica zámen, Zdroj: Autor.

Na granularite 30 môžeme vidieť veľmi dobré výsledky aj čo sa týka presnosti predikcií, aj profitability siete. Profitabilita výrazne kolísala, ale končí na úrovni okolo \$55 000, čo je cca. 550% pôvodne investovanej čiastky.




Obrázek 11.25: Profitabilita siete pri obchodovaní akcií EA, granularita 180 a príslušná matica zámen, Zdroj: Autor.

Vzhľadom na obmedzený počet scalogramov na tejto úrovni granularity je ťažké priložiť veľkú váhu tomuto prípadu, ale môžeme pozorovať, že sieť správne rozpoznala všetky scalogramy z testovacieho datasetu. Vzhľadom na vysokú granularitu je aj profit siete v tomto prípade markantný, až cca. \$25 000.



Obrázek 11.26: Profitabilita siete pri obchodovaní akcií AMD, granularita 1 a príslušná matica zámen, Zdroj: Autor.

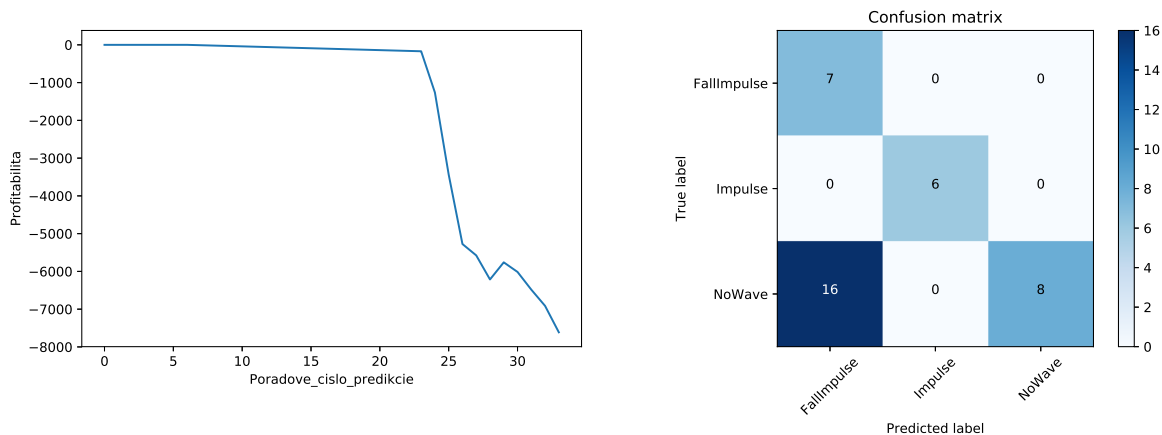
Z matice zámen je vidieť že sieť mala v tomto prípade problém správne rozoznať impulzy, rozoznala iba 1 impulz správne. To sa aj prejavuje na grafe profitu, ktorý vykazuje iba stratu od samotného začiatku simulovaného obchodovania.



Obrázek 11.27: Profitabilita siete pri obchodovaní akcií AMD, granularita 6 a príslušná matica zámen, Zdroj: Autor.

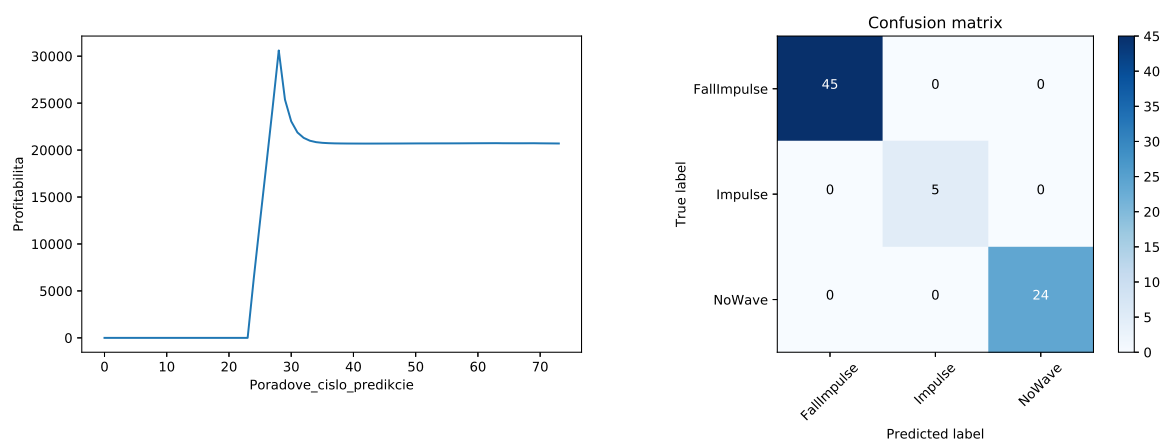
S úrovňou granularity 6 je sieť úspešná, čo sa týka presnosti rozpoznávania. Avšak táto úspešnosť sa, ako vidíme na grafe, neprenesie do profitu. To indikuje, že zvolená stratégia obchodovania, napriek jej modelovaniu na základe Elliottovej teórie, v tomto prípade zlyhala. Chybou v tomto prípade môže byť vyššia náhodnosť datasetu AMD, ako je aj zjavné z hodnoty Hurstovho exponentu.







Obrázek 11.28: Profitabilita siete pri obchodovaní akcií AMD, granularita 30 a príslušná matica zámen, Zdroj: Autor.

Na tejto granularite sieť vykazuje veľmi zlé výsledky už pri presnosti rozpoznávania, kedy príliš často klasifikuje dané testovacie scalogramy ako klesajúce impulzy, namiesto korekcií. To sa následne podľa očakávania odrazí aj v profitabilite siete, ktorá končí v záporných číslach. Príčinou neúspechu v tomto prípade môže byť nízky počet identifikovaných vzorov, čo má za následok menší počet scalogramov na tréning siete, čo následne spôsobí nízku presnosť rozpoznávania, nakoľko sieť pri tréningu nemala možnosť sa naučiť dostatok informácií.




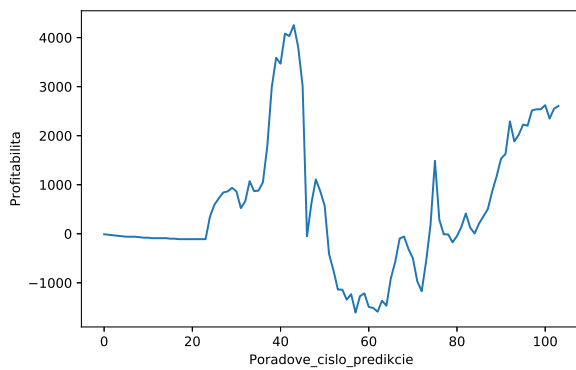
Obrázek 11.29: Profitabilita siete pri obchodovaní akcií AMD, granularita 180 a príslušná matica zámen, Zdroj: Autor.

V tomto prípade si sieť viedla veľmi dobre, môžeme pozorovať, že bola pri rozpoznávaní bezchybná, a tento krát sa to tiež premietlo do profitability.





Obrázek 11.30: Profitabilita siete pri obchodovaní akcií INTU, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Vzhľadom na nižší počet testovacích scalogramov musíme konštatovať, že spolu 12 chýb pri klasifikácii je pomerne veľa. Aj tak ale sieť dosiahla 76%-tnú presnosť a skončila test s profitom zhruba \$800.





Obrázek 11.31: Profitabilita siete pri obchodovaní akcií INTU, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Sieť aj v tomto teste ukázala vysokú presnosť rozpoznávania zjednodušeného setu vzorov Elliottovej teórie a taktiež opäť dosiahla zisk. Tentokrát je zisk zhruba na úrovni 30% pôvodného kapitálu \$10 000.




Obrázek 11.32: Profitabilita siete pri obchodovaní akcií INTU, granularita 30 a príslušná matica zámien, Zdroj: Autor.




Obrázek 11.33: Profitabilita siete pri obchodovaní akcií INTU, granularita 180 a príslušná matica zámien, Zdroj: Autor.

Na vyšších úrovniach granularity môžeme pri testovaní na akciách INTU znovu vidieť dobrú presnosť rozpoznávania, avšak sieť v oboch prípadoch skončí v masívnej strate. V tomto prípade však nemôžeme povedať, že by išlo o dataset s vysokou hodnotou Hurstovho exponenta,  $H = 0.68$ .




Obrázek 11.34: Profitabilita siete pri obchodovaní akcií CTXS, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Aj v prípade simulácie obchodovania s akciami CTXS si na najnižšej granularite rozpoznávania vzorov sieť viedla z hľadiska presnosti klasifikácie veľmi dobre. Z grafu profitability môžeme sledovať, že po zlom štarte sa sieti nakoniec podarilo stratu pokryť a ísť do plusových čísiel.




Obrázek 11.35: Profitabilita siete pri obchodovaní akcií CTXS, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Z matice zámen vidíme, že sieť zle rozpoznala až 19 korekcií - považovala ich za impulzy. To sa odrazilo na profitabilite, ktorá sa síce koncom testu blížila aspoň k hodnote pôvodnej investície, avšak skončila v zápore.





Obrázek 11.36: Profitabilita siete pri obchodovaní akcií CXTS, granularita 30 a príslušná matica zámen, Zdroj: Autor.

Na grafe profitability vidieť, že sieť mala zo začiatku sériu správnych rozpoznání ale následne väčšinu profitu stratila. Presnosť rozpoznanie je však na dobrej úrovni 85%.





Obrázek 11.37: Profitabilita siete pri obchodovaní akcií CXTS, granularita 180 a príslušná matica zámen, Zdroj: Autor.

Na najvyššej granularite aj pri akcii CXTS môžeme pozorovať takmer bezchybnú presnosť rozpoznania, avšak obrovskú kapitálovú stratu. Tento výsledok opäť signalizuje nedostatok v návrhu stratégie obchodov na burze, alebo v nedostatočnej schopnosti vybraných vzorov Elliottovej vlnovej teórie správne modelovať pohyby kapitálového trhu.




Obrázek 11.38: Profitabilita siete pri obchodovaní akcií SYMC, granularita 1 a príslušná matica zámen, Zdroj: Autor.

Z tohto testu vyšla sieť pomerne dobre, s vysokou úspešnosťou klasifikácie, aj s realizáciou profitu na simulovaných obchodoch.



Obrázek 11.39: Profitabilita siete pri obchodovaní akcií SYMC, granularita 6 a príslušná matica zámen, Zdroj: Autor.

Podobne ako v iných testoch sieť zamenila impulzy za korekcie, ale opäť vhodne zvolené rozhodnutie v prípade korekcie držať pozíciu, respektíve neobchodovať sa odrazilo kladne na profitabilite.



Obrázek 11.40: Profitabilita siete pri obchodovaní akcií SYMC, granularita 30 a príslušná matica zámen, Zdroj: Autor.

Naoko sieť na začiatku dlho negeneruje zisk, to je však spôsobené iba škálou grafu, keďže ku koncu profit vystrelí až na takmer \$1 milión. Takto vysoký profit je určite spôsobený aj obchodovaním na vysokej granularite, čo sa odrazí na vysokých zmenách kurzu, kvôli dlhším časovým úsekom medzi nákupom a predajom akcií. Sieť však nesprávne označila korekcie za klesajúce impulzy, čo sa odrazilo na prudkom poklese ku koncu testu.

Výsledky testov sú zhrnuté v nasledujúcich tabuľkách, kde sú datasey rozdelené podľa toho, či boli prítomné v pôvodnom tréningovom datasee alebo nie.

Tabulka 11.2: Tabuľka výsledkov testovania navrhutej CNN I, Zdroj: Autor.

Akcia/Granularita	Priemerný profit	Priemerná presnosť	Hurstov exponent	Kurz
AAPL	-350	0.84	0.915	\$211.75
1	-850	0.68	0.915	
6	-4700	0.9	1.0766	
30	4500	0.94	1.072	
CSCO	666.667	0.85	0.810	\$ 54.94
1	3000	0.77	0.810	
6	7000	0.78	0.902	
30	-8000	1	1.058	
MSFT	-19033.333	0.763	0.759	\$128.9
1	2250	0.67	0.759	
6	650	0.88	0.878	
30	-60000	0.74	1.049	
NVDA	5633.333	0.757	0.897	\$183.01
1	-1100	0.92	0.897	
6	25000	0.62	0.958	
30	-7000	0.73	1.048	
TXN	4800	0.67	0.786	\$117.47
1	1400	0.88	0.786	
6	-3000	0.78	0.876	
30	16000	0.35	0.953	
Celkový priemer	-1656.67	0.78		

V tabuľke môžeme vidieť, že priemerná presnosť rozpoznávania pri akciách z pôvodného tréningového datasetu sa pohybuje na úrovni 78% a priemerný profit je -1656.67. Kurz ani granularita nevyzerajú mať vplyv na presnosť, či profitabilitu siete.



Tabulka 11.3: Tabulka výsledkov testovania navrhnutej CNN II, Zdroj: Autor.


Akcia/Granularita	Priemerný profit	Priemerná presnosť	Hurstov exponent	Kurz
AMD	-7500	0.71	0.965	\$28.22
1	-4700	0.75	0.9647	
6	-10000	0.81	1.077	
30	-7800	0.569	1.148	
CTXS	1783.333	0.843	0.886	\$99.15
1	850	0.95	0.886	
6	-500	0.72	1.073	
30	5000	0.86	1.124	
EA	3333.333	0.813	0.758	\$92.5
1	3000	0.64	0.758	
6	35000	0.85	0.798	
30	-28000	0.95	0.913	
INTU	-21366.667	0.84	0.683	\$248.86
1	900	0.78	0.683	
6	3000	0.89	0.719	
30	-68000	0.85	0.789	
SYMC	205083.333	0.817	0.620	\$23.55
1	750	0.86	0.676	
6	14500	0.81	0.696	
30	600000	0.78	0.620	
Celkovo	36266.67	0.80		

Na datasete predtým neznámych akcií pozorujeme jemne vyššiu presnosť na úrovni 80%, ako aj kladný priemerný profit. Opäť nevidno spojenie medzi hodnotou kurzu alebo granularity a profitu. Ale na základe oboch tabuliek môžeme vyjadriť hypotézu, že existuje korelácia medzi hodnotou Hurstovho exponentu a profitom siete pri simulovanom obchode na kapitálovom trhu.

Môžeme povedať, že navrhnutý systém predikcie trendu dosahuje v týchto testoch zmiešané výsledky. Presnosť rozpoznávania sa síce udržiava pomerne vysoká, no sieť často nedokáže zvolenou stratégiou obchodovania dosiahnuť dlhodobější zisk.

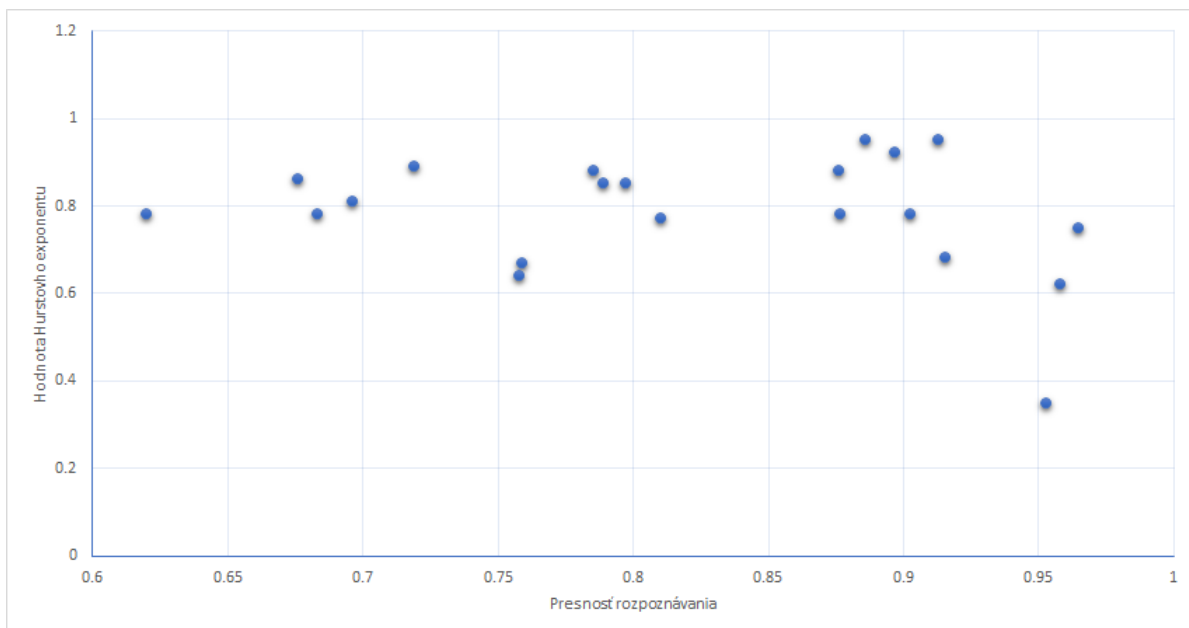
## 12. Zhodnotenie

Z testovania siete LSTM je zrejmé, prečo sa stala často používanou v oblasti podpory investičného rozhodovania. Aj sieť s pomerne nižšou zložitostou sa bola schopná naučiť správanie vybranej časovej rady v čase a následne s vysokou presnosťou predpovedať vývoj trendu. Na druhej strane systém navrhnutý v tejto práci, založený na využití zjednodušeného modelu Elliottovej vlnovej teórie a na rozpoznávaní scalogramov zo jej vzorov s použitím konvolučnej neurónovej siete, dosiahol zmiešané výsledky. V šiestich testovaných prípadoch bola sieť zisková, a v štyroch stratová. Cieľom testovania bolo aj sledovať vplyv faktorov, ako napr. výšky kurzu akcie, hodnoty Hurstovho exponentu testovaného datasetu a úrovne granularity rozpoznávaných vzorov, na výkon navrhnutého systému pri testovaní. Vplyv vybraných faktorov je znázornený na nasledujúcich grafoch.




Obrázek 12.1: Graf vzťahu medzi Hurstovým exponentom a profitabilitou siete, Zdroj: Autor.

Z grafu môžeme odvodiť záver, že dosiahnutá profitabilita počas simulovaného obchodu na burze je korelovaná s hodnotou Hurstovho exponentu daného datasetu. Testy v ktorých bola použitá dátová rada s nižším Hurstovým exponentom boli v profitabilite úspešnejšie ako ostatné.



Obrázek 12.2: Graf vzťahu medzi Hurstovým exponentom a presnosťou siete, Zdroj: Autor.

V prípade Hurstovho exponentu a presnosti rozpoznávania sa v daných testoch nejavia známky korelácie.



Obrázek 12.3: Graf vzťahu medzi kurzom akcie a profitabilitou siete, Zdroj: Autor.

Na základe tohto grafu tiež nemožno konštatovať spojenie medzi kurzom akcie a profitabilitou siete. Z grafov a vyššie uvedených tabuliek 11.2 a 11.3 môžeme teda konštatovať, že zo sledovaných veličín má vplyv na úspešnosť, resp. profitabilitu siete iba hodnota Hurstovho exponentu .

Možnou príčinou, prečo tu navrhnutý systém napriek dobrej presnosti rozpoznávania dosahuje iba zmiešaných výsledkov profitability môže byť veľmi jednoduchá stratégia obchodovania zvolená v testovaní. Pri reálnej aplikácii by sme mohli napríklad použiť príkazy typu STOP LOSS na zníženie straty, ak by sa trend nemenil podľa predikcií systému. Nepochybne je ďalším faktorom aj zjednodušenie rozpoznávaných vzorov Elliottovej teórie. Okrem uvoľnenia definície impulzu, s cieľom zlepšiť schopnosti siete sa naučiť rozpoznávať tu použité vzory, by určite prišlo k zlepšeniu profitability aj rozpoznávaním zložitejších vzorov, ako napríklad viacerých typov korekcií - trojuholníkov, či rovín - ale hlavne rozpoznávaním predĺžení, či zlyhaní impulzov. To by nám dovolilo lepšie zvoliť stratégiu obchodovania, ako aj systému presnejšie predpovedať kedy dôjde k otočeniu trendu. K tomu by však bolo nutné rozšíriť generovanie scalogramov aj na spomínané vzory. To vzhľadom na potrebný objem dát a časovú, respektíve výpočtovú náročnosť ich generovania nebolo v tejto práci možné pokryť.

Záverom môžeme konštatovať, že nový spôsob predikcie trendu kurzu akcií pomocou rozpoznávania scalogramov konvulčnou neurónovou sieťou navrhnutý v tejto práci je možnou alternatívou k tradičnejším prístupom, ako napríklad použitie siete typu Long-Short Term Memory. Navrhnutý systém preukázal dobrú presnosť rozpoznávania priemerne na úrovni 78% pri testovaní na desiatich datasetoch, skrz 4 úrovne granularity rozpoznávaných vzorov. Systém predikcie trendu je z hľadiska použitia systému na automatizovanie obchodovania na burze v tu prezentovanej podobe príliš riskantný s prihliadnutím na jeho zmiešané výsledky simulovanej profitability. Lepším kandidátom na využitie ostáva sieť typu Long-Short Term Memory, ktorá sa vďaka svojim vlastnostiam lepšie hodí na predpovedanie časových rád. Avšak tu navrhnutý systém preukázal potenciál byť taktiež použiteľnou alternatívou pri zvolení vhodnej akcie, ktorej časová rada sa vyznačuje Hurstovým exponentom v rozmedzí  $\langle 0.6, 0.85 \rangle$ , a vylepšení navrhutej jednoduchej obchodovacej stratégie.

## 12.1. Ekonomický prínos

Navrhnutý prístup predikcie trendu môže nájsť využitie napríklad v úspešných podnikoch, ktoré majú záujem investovať časť svojho zisku do vysoko likvidnej investície, napr. na kapitálovom trhu. V rámci finančného oddelenia potom môže autorom navrhnutý systém byť použitý na informovanie rozhodnutí príslušných zamestnancov o nákupe a predaji, resp. uzatváraní obchodov. Prípadne v podniku s vyššou toleranciou riziku by bolo možné využiť systém ak na autonómne obchodovanie a ušetriť tak náklady na zamestnancov, resp. vynaložené na analýzu trhu a plánovanie obchodov. Navrhnutý systém tiež môže nájsť využitie v investičných fondoch alebo iných investičných spoločnostiach, ktoré spravujú investície svojich zákazníkov, ako nástroj podpory rozhodovania pre ich zamestnancov. Zamestnanci by navrhnutý systém mohli používať podobne ako využívajú technickú, či fundamentálnu analýzu. Mohli by sme teda o použití tohto systému uvažovať ako o nástroji znižovania rizika ich podnikania tým, že svojím zamestnancom poskytnú širšie spektrum informácií, podľa ktorých sa budú rozhodovať a teda bude menej pravdepodobné, že spravia pri obchodovaní chybu. V prípade používania Elliottovej teórie by taktiež mohlo ísť o jej automatizáciu, avšak na to už existujú aj iné programy a moduly.

## 12.2. Ďalšie smerovanie práce

Systém navrhnutý v tejto práci využíva skôr iba základy Elliottovej vlnovej teórie, a jej rozšírením by tak mohlo byť využitie práce [25] na expanziu dát použitých na generovanie scalogramov o ďalšie vzory z Elliottovej teórie. Medzi kľúčové vzory by sme mohli považovať predĺženia a zlyhania impulzov, ktoré by mohli mať výraznejší dopad na presnosť predikcií trendu. Scalogramy reprezentujúce tieto vzory by nám dovolili ich rozpoznávanie pomocou tu navrhnutej konvolučnej neurónovej siete a teda následne prepracovanejšie využitie Elliottovej teórie pri vytváraní a aplikovaní obchodovacej stratégie na kapitálových trhoch. Ďalšou možnosťou by bolo navrhnutie systému využívajúceho, okrem tu navrhnutej siete, aj druhú sieť, napríklad typu LSTM a ich prepojenie, alebo využitie v tandeme, kedy by výsledné predikcie boli informované predikciami oboch sietí a tak by mohli vzájomne vykrývať svoje nedostatky.

## 13. Záver

V rámci tejto práce sú postupne uvedené teoretické východiska, na ktorých je práca založená, hlavne z oblastí neurónových sietí, technickej analýzy kapitálových trhov a investičného rozhodovania. Následne po poskytnutí krátkeho prehľadu o použití umelej inteligencie v prostredí investičného rozhodovania a obchodovania na kapitálových trhoch nasleduje jadro tejto práce – nový, autorom navrhnutý spôsob predikcie trendu na kapitálových trhoch založený na rozpoznávaní vzorov Elliottovej vlnovej teórie pomocou neurónovej siete.

Navrhnutý systém je založený na princípe rozpoznávania vybraných vzorov Elliottových vln – konkrétne impulzov a korekcií. Z impulzov sieť rozpoznáva klesajúce a rastúce impulzy, a za korekcie rozpoznáva všetky ostatné postupnosti bodov vybraného datasetu kurzu akcie. Hlavným prínosom tejto práce je použitie scalogramov na reprezentáciu vybraných vzorov, teda rozkladom postupnosti hodnôt, predstavujúcich tieto vzory, pomocou spojitaj vlnkovej transformácie podľa Morletovej vlnky. Tento prístup som zvolil na základe podobného prístupu používaného v medicíne na analýzu a predikciu srdcových chorôb z nameraných hodnôt EKG, ktoré su podobne ako kurz akcie reprezentované časovou radou. Základom systému je konvolučná neurónová sieť trénovaná na scalogramoch z datasetu obsahujúceho historické dáta desiatich vybraných akcií. Navrhnutý systém potom funguje na princípe generovania scalogramov z historických dát akcie, s ktorou chce používateľ obchodovať, a pretrénovaní časti neurónovej siete pomocou princípu transfer learning. Rozpoznávaním týchto vzorov potom na základe Elliottovej teórie systém predikuje vývoj trendu v nasledujúcom období a generuje jeden zo signálov pre obchod na kapitálovom trhu – Sell, Buy alebo Hold.

Pre zhodnotenie navrhnutého prístupu bola implementovaná aj jednoduchá sieť typu Long-Short Term Memory, ktorá je priamo vyvinutá s cieľom analýzy časových rád. Pri testovaní sa preukázala schopnosť navrhnutej siete rozpoznávať jednotlivé zvolené vzory Elliottovej teórie zo scalogramov s priemernou presnosťou cca. 78%, čím sa naplnil cieľ tejto práce - možnosť využitia tohto prístupu pre predikciu trendu na kapitálovom trhu. V rámci simulácie využitia celého navrhnutého systému na obchodovanie s akciami bol dosiahnutý záver, že navrhnutý systém pri obchodovaní správne vybranej akcie, s hodnotou Hurstovho exponentu v rozmedzí  $\langle 0.6, 0.85 \rangle$ , má predpoklady na realizáciu kapitálového zisku. Avšak pri porovnaní s tradičnejším prístupom použitia siete typu Long-Short Term Memory má navrhnutý systém o poznanie nižšiu profitabilitu.

V praxi môže byť navrhovaný prístup využitý napríklad pre podporu rozhodovania zamestnancov investičných fondov, pri obchodovaní na kapitálovom trhu obdobne ako je tomu s využitím technických, či fundamentálnych analýz.

Ďalším predmetom záujmu by v spojení s touto prácou mohlo byť rozšírenie rozpoznávaných vzorov, čo by systému dovolilo robiť komplexnejšie rozhodnutia a dávať presnejšie odporúčenia, čím by sa mala zvýšiť celková využiteľnosť systému v praxi.

# Literatura

- [1] Accenture: Accenture Technology Vision 2018. [https://www.accenture.com/t20180208T172438Z\\_\\_w\\_\\_/\\_us-en/\\_acnmedia/Accenture/next-gen-7/tech-vision-2018/pdf/Accenture-TechVision-2018-Tech-Trends-Report.pdf](https://www.accenture.com/t20180208T172438Z__w__/_us-en/_acnmedia/Accenture/next-gen-7/tech-vision-2018/pdf/Accenture-TechVision-2018-Tech-Trends-Report.pdf), 2018, accessed: 2019-01-10.
- [2] Chen, H.; Zhang, P.; Bai, H.; aj.: Deep convolutional neural network with scalogram for audio scene modeling. In Proc. Interspeech 2018, 2018, s. 3304--3308.
- [3] Dixon, M.; Klabjan, D.; Bang, J. H.: Classification-based financial markets prediction using deep neural networks. *Algorithmic Finance*, , č. Preprint, 2017: s. 1--11.
- [4] Dostál, P.: *Soft computing v podnikatelství a veřejné správě*. Brno: Akademické nakladatelství CERM, vyd. 1. vydání, 2015, ISBN 978-80-7204-896-0.
- [5] Duchi, J.; Hazan, E.; Singer, Y.: Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, ročník 12, č. Jul, 2011: s. 2121--2159.
- [6] Faust, O.; Acharya, U. R.; Adeli, H.; aj.: Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis. *Seizure*, ročník 26, 2015: s. 56--64.
- [7] Fischer, T.; Krauss, C.: Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, ročník 270, č. 2, 2018: s. 654--669.
- [8] Hochreiter, S.; Schmidhuber, J.: Long short-term memory. *Neural computation*, ročník 9, č. 8, 1997: s. s. 1735--1780.
- [9] Hurst, H. E.: Methods of using long-term storage in reservoirs. *Proceedings of the Institution of Civil Engineers*, ročník 5, č. 5, 1956: s. 519--543.
- [10] Inc., A. V.: Alpha Vantage API Documentation 2018. <https://www.alphavantage.co/documentation/>, 2019, accessed: 2019-05-09.
- [11] Madaleno, M.; Pinho, C.: International stock market indices comovements: a new look. *International Journal of Finance & Economics*, ročník 17, č. 1, 2012: s. 89--102.
- [12] Mařík, V.: *Umělá inteligence*. [Díl] 4. Praha: Academia, první vydání, 2003, ISBN 80-200-1044-0.
- [13] Naccache, T.: Oil price cycles and wavelets. *Energy Economics*, ročník 33, č. 2, 2011: s. 338--352.
- [14] Nguyen, M.: Illustrated Guide to LSTM's and GRU's: A step by step explanation. <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>, 2019, accessed: 2019-05-09.

- [15] Panetta, K.: Gartner Top 10 Strategic Technology Trends for 2019. <https://www.gartner.com/smarterwithgartner/gartner-top-10-strategic-technology-trends-for-2019>, 2019, accessed: 2019-01-10.
- [16] Ramli, M.; Junoh, A.; Muhamad, W.; aj.: Elliott Wave Pattern Recognition for Forecasting GBP/USD Foreign Exchange Market. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, ročník 10, č. 1-13, 2018: s. 31--35.
- [17] Režňáková, M.: Finanční management. II. část. Učební texty vysokých škol, Brno: Zdeněk Novotný, první vydání, 2002, ISBN 80-214-2250-5.
- [18] Selvin, S.; Vinayakumar, R.; Gopalakrishnan, E.; aj.: Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, IEEE, 2017, s. 1643--1647.
- [19] Sojka, Z.; Dostál, P.: Elliottovy vlny. Brno: Tribun EU, první vydání, 2008, ISBN 978-80-7399-630-7.
- [20] Springwise: Artificial Intelligence Innovation Report 2018. <https://www2.deloitte.com/content/dam/Deloitte/de/Documents/Innovation/Artificial-Intelligence-Innovation-Report-2018-Deloitte.pdf>, 2018, accessed: 2019-05-09.
- [21] The MathWorks, I.: Classify Time Series Using Wavelet Analysis and Deep Learning. <https://www.mathworks.com/help/wavelet/examples/signal-classification-with-wavelet-analysis-and-convolutional-neural-networks.html#d117e8575>, 2019, accessed: 2019-05-10.
- [22] The MathWorks, I.: Continuous Wavelet Transform and Scale-Based Analysis. <https://www.mathworks.com/help/wavelet/gs/continuous-wavelet-transform-and-scale-based-analysis.html>, 2019, accessed: 2019-05-10.
- [23] Torrey, L.; Shavlik, J.: Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*, IGI Global, 2010, s. 242--264.
- [24] Veselá, J.; Oliva, M.: Technická analýza na akciových, měnových a komoditních trzích. Praha: Ekopress, první vydání, 2015, ISBN 978-80-87865-22-4.
- [25] Volná, E.; Kotyrba, M.; Oplatková, Z. K.; aj.: Elliott waves classification by means of neural and pseudo neural networks. *Soft Computing*, ročník 22, č. 6, 2018: s. 1803--1813.
- [26] Weckman, G. R.; Lakshminarayanan, S.; Marvel, J. H.; aj.: An integrated stock market forecasting model using neural networks. *International Journal of Business Forecasting and Marketing Intelligence*, ročník 1, č. 1, 2008: s. 30--49.



# Seznam obrázků

4.1	Matematický model neurónu - perceptron, Zdroj: Autor, podľa [4]	11
4.2	Aktivačné funkcie zľava-doprava - sigmoid, tanh, ReLU a softmax, Zdroj: Autor	13
4.3	Schéma jednoduchej viacvrstvovej neurónovej siete, Zdroj: Autor, podľa [12]	13
4.4	Schéma neurónu siete typu Long-Short Term Memory, Zdroj: Autor, podľa [14]	19
6.1	Impulz a predĺženie impulzu, Zdroj: Autor, podľa [19]	27
6.2	Typy korekcií, zľava doprava - cikcak, rovina a trojuholník, Zdroj: Autor, podľa [19]	28
7.1	Graf Morletovej vlnky, Zdroj: Autor.	28
10.1	Graf Morletovej vlnky, Zdroj: Autor.	33
10.2	Graf klesajúceho impulzu a jeho scalogram z dát spoločnosti Tesla	34
10.3	Graf impulzu a jeho scalogram z dát spoločnosti Apple, Zdroj: Autor	34
10.4	Graf korekcie a jeho scalogram z dát spoločnosti Apple, Zdroj: Autor	34
10.5	XOR impulz, korekcia, Zdroj: Autor	35
10.6	XOR korekcia, klesajúci impulz, Zdroj: Autor	35
10.7	XOR impulz a klesajúci impulz, Zdroj: Autor	36
10.8	Reprezentácia navrhnutého systému tréningu konvolučnej neurónovej siete, Zdroj: Autor.	37
10.9	Graf zobrazujúci časovú radu kurzu akcií spoločnosti Tesla vo vybraných granularitách, Zdroj: Autor.	40
10.10	Reprezentácia modelu použitej konvolučnej siete, Zdroj: Autor	43
10.11	Vizualizácia presnosti a funkcie loss v priebehu tréningu, Zdroj: Autor.	44
10.12	Matica zámen tréningovej navrhnutéj konvolučnej siete, Zdroj: Autor	45
10.13	Reprezentácia vrstiev modelu, Zdroj: Autor.	47
10.14	Vizualizácia presnosti a funkcie loss v priebehu tréningu, Zdroj: Autor	48
10.15	Matica zámen implementovanej siete typu LSTM, Zdroj: Autor.	49
11.1	Schéma testovacieho procesu, Zdroj: Autor	50
11.2	Profitabilita siete pri obchodovaní akcií AMZN a príslušná matica zámen, Zdroj: Autor.	53
11.3	Detail profitability siete, akcie AMZN, Zdroj: Autor.	53
11.4	Profitabilita siete pri obchodovaní akcií CSCO a príslušná matica zámen, Zdroj: Autor.	54
11.5	Profitabilita siete pri obchodovaní akcií MSFT a príslušná matica zámen, Zdroj: Autor.	54
11.6	Profitabilita siete pri obchodovaní akcií TXN, granularita 1 a príslušná matica zámen, Zdroj: Autor.	55
11.7	Profitabilita siete pri obchodovaní akcií TXN, granularita 6 a príslušná matica zámen, Zdroj: Autor.	55
11.8	Profitabilita siete pri obchodovaní akcií TXN, granularita 30 a príslušná matica zámen, Zdroj: Autor.	56
11.9	Profitabilita siete pri obchodovaní akcií MSFT, granularita 1 a príslušná matica zámen, Zdroj: Autor.	56
11.10	Profitabilita siete pri obchodovaní akcií MSFT, granularita 6 a príslušná matica zámen, Zdroj: Autor.	57

11.11	Profitabilita siete pri obchodovaní akcií MSFT, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	57
11.12	Profitabilita siete pri obchodovaní akcií MSFT, granularita 180 a príslušná matica zámen, Zdroj: Autor. . . . .	58
11.13	Profitabilita siete pri obchodovaní akcií AAPL, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	58
11.14	Profitabilita siete pri obchodovaní akcií AAPL, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	59
11.15	Profitabilita siete pri obchodovaní akcií AAPL, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	59
11.16	Profitabilita siete pri obchodovaní akcií CSCO, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	60
11.17	Profitabilita siete pri obchodovaní akcií CSCO, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	60
11.18	Profitabilita siete pri obchodovaní akcií CSCO, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	61
11.19	Profitabilita siete pri obchodovaní akcií NVDA, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	61
11.20	Profitabilita siete pri obchodovaní akcií NVDA, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	62
11.21	Profitabilita siete pri obchodovaní akcií NVDA, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	62
11.22	Profitabilita siete pri obchodovaní akcií EA, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	63
11.23	Profitabilita siete pri obchodovaní akcií EA, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	63
11.24	Profitabilita siete pri obchodovaní akcií EA, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	64
11.25	Profitabilita siete pri obchodovaní akcií EA, granularita 180 a príslušná matica zámen, Zdroj: Autor. . . . .	64
11.26	Profitabilita siete pri obchodovaní akcií AMD, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	65
11.27	Profitabilita siete pri obchodovaní akcií AMD, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	65
11.28	Profitabilita siete pri obchodovaní akcií AMD, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	66
11.29	Profitabilita siete pri obchodovaní akcií AMD, granularita 180 a príslušná matica zámen, Zdroj: Autor. . . . .	66
11.30	Profitabilita siete pri obchodovaní akcií INTU, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	67
11.31	Profitabilita siete pri obchodovaní akcií INTU, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	67
11.32	Profitabilita siete pri obchodovaní akcií INTU, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	68
11.33	Profitabilita siete pri obchodovaní akcií INTU, granularita 180 a príslušná matica zámen, Zdroj: Autor. . . . .	68

11.34	Profitabilita siete pri obchodovaní akcií CTXS, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	69
11.35	Profitabilita siete pri obchodovaní akcií CTXS, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	69
11.36	Profitabilita siete pri obchodovaní akcií CTXS, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	70
11.37	Profitabilita siete pri obchodovaní akcií CTXS, granularita 180 a príslušná matica zámen, Zdroj: Autor. . . . .	70
11.38	Profitabilita siete pri obchodovaní akcií SYMC, granularita 1 a príslušná matica zámen, Zdroj: Autor. . . . .	71
11.39	Profitabilita siete pri obchodovaní akcií SYMC, granularita 6 a príslušná matica zámen, Zdroj: Autor. . . . .	71
11.40	Profitabilita siete pri obchodovaní akcií SYMC, granularita 30 a príslušná matica zámen, Zdroj: Autor. . . . .	72
12.1	Graf vzťahu medzi Hurstovým exponentom a profitabilitou siete, Zdroj: Autor. . . . .	75
12.2	Graf vzťahu medzi Hurstovým exponentom a presnosťou siete, Zdroj: Autor. . . . .	76
12.3	Graf vzťahu medzi kurzom akcie a profitabilitou siete, Zdroj: Autor. . . . .	76

# Seznam tabulek

4.1	Definícia matice zámen, Zdroj: Autor. . . . .	17
10.1	Tabuľka pravidiel generovania predikcií, Zdroj: Autor. . . . .	37
10.2	Východiskové dáta zo služby AlphaVantage, Zdroj: Autor. . . . .	38
10.3	Tabuľka rozloženia dát, Zdroj: Autor. . . . .	44
10.4	Tabuľka hodnôt precision, recall a F1-score navrhnutej konvolučnej siete, Zdroj: Autor. . . . .	46
10.5	Tabuľka hodnôt precision, recall a F1-score trénovanej LSTM neurónovej siete, Zdroj: Autor. . . . .	49
11.1	Tabuľka testovacích datasetov, Zdroj: Autor. . . . .	52
11.2	Tabuľka výsledkov testovania navrhnutej CNN I, Zdroj: Autor. . . . .	73
11.3	Tabuľka výsledkov testovania navrhnutej CNN II, Zdroj: Autor. . . . .	74