



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**

FACULTY OF INFORMATION TECHNOLOGY

**ÚSTAV INTELIGENTNÍCH SYSTÉMŮ**

DEPARTMENT OF INTELLIGENT SYSTEMS

**INTEGRACE UMĚLÉ INTELIGENCE DO OBCHODU S  
RYCHLOOBRÁTKOVÝM ZBOŽÍM**

INTEGRATION OF ARTIFICIAL INTELLIGENCE IN TRADE WITH

FAST-MOVING CONSUMER GOODS

**BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

**AUTOR PRÁCE**

AUTHOR

**JURAJ BAGI**

**VEDOUcí PRÁCE**

SUPERVISOR

**Ing. JAROSLAV ROZMAN, Ph.D.**

BRNO 2024

## Zadání bakalářské práce



156681

Ústav: Ústav inteligentních systémů (UITS)  
Student: **Bagi Juraj**  
Program: Informační technologie  
Název: **Integrace umělé inteligence do obchodu s rychloobrátkovým zbožím**  
Kategorie: Umělá inteligence  
Akademický rok: 2023/24

### Zadání:

1. Nastudujte metody umělé inteligence používané v oblasti obchodu s rychloobrátkovým zbožím.
2. Navrhněte systém, který na základě různých faktorů (např. počasí, datum nebo trvanlivost zboží) doporučí obchodní firmě jaké množství a jakého zboží objednat.
3. Navržený systém implementujte
4. Implementovaný systém otestujte na reálných datech.

### Literatura:

- Tonbul, Taha. (2019). Sales Forecast in FMCG Sector with Artificial Neural Networks. 10.13140/RG.2.2.22317.23529.
- Tarallo E, Akabane GK, Shimabukuro CI, Mello J, Amancio D. Machine Learning in Predicting Demand for Fast-Moving Consumer Goods: An Exploratory Research. IFAC-PapersOnLine, ISSN 2405-8963; 2019.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Rozman Jaroslav, Ing., Ph.D.**  
Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.  
Datum zadání: 1.11.2023  
Termín pro odevzdání: 9.5.2024  
Datum schválení: 6.11.2023

## Abstrakt

Presné predpovede predaja sú kľúčové pre prevádzkovú efektivitu v sektore rýchloobrátkového spotrebného tovaru (FMCG). Táto práca skúma uplatnenie modelov Long Short-Term Memory (LSTM), špecializovaného typu rekurentných neurónových sietí, s cieľom zvýšiť presnosť predpovedí predaja. Na rozdiel od tradičných štatistických metód sú LSTM schopné zachytávať časové závislosti v údajoch o predaji, čím potenciálne ponúkajú presnejšie prognózy. Aplikáciou modelov LSTM na historické údaje o predaji z potravinárskej spoločnosti tento výskum preukazuje zlepšenie v porovnaní s konvenčnými predikčnými technikami. Zistenia naznačujú, že LSTM môžu významne pomôcť spoločnostiam v oblasti FMCG pri optimalizácii riadenia zásob a plánovaní dopytu, čím prispievajú cennými pohľadmi do aplikácií umelej inteligencie v riadení dodávateľského reťazca. Tieto výsledky zdôrazňujú praktické dôsledky pre zainteresované strany v sektore FMCG, aby prijali pokročilé technológie umelej inteligencie s cieľom udržať si konkurencieschopnosť v dynamickom trhovom prostredí.

## Abstract

Accurate sales forecasting is pivotal for operational efficiency in the Fast-Moving Consumer Goods (FMCG) sector. This thesis explores the application of Long Short-Term Memory (LSTM) models, a specialized form of recurrent neural networks, to enhance the precision of sales predictions. Unlike traditional statistical methods, LSTMs are adept at capturing temporal dependencies within sales data, potentially offering more accurate forecasts. By applying LSTM models to historical sales data from a food industry company, this research demonstrates improvements over conventional forecasting techniques. The findings suggest that LSTMs can significantly help FMCG companies in optimizing inventory management and demand planning, thereby contributing valuable insights into artificial intelligence applications in supply chain management. These results emphasize the practical implications for FMCG stakeholders to embrace advanced artificial intelligence technologies to remain competitive in a dynamic market environment.

## Kľúčové slová

Rýchloobrátkový spotrebný tovar, Rekurentné neurónove siete, Dlhodobá krátkodobá pamäť

## Keywords

Fast-moving consumer goods (FMCG), Recurrent neural network, Long short-term memory (LSTM)

## Citácia

BAGI, Juraj. *Integrace umělé inteligence do obchodu s rychloobrátkovým zbožím*. Brno, 2024. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Jaroslav Rozman, Ph.D.

# Integrace umělé inteligence do obchodu s rychloobrátkovým zbožím

## Prehlásenie

Prehlasujem, že túto bakalársku prácu som vypracoval samostatne pod vedným pána Ing. Jaroslava Rozmana Ph.D. Uviedol som všetky literárne pramene, publikácie a ďalšie zdroje, z ktorých som čerpal. Ďalšie cenné informácie mi poskytla pani Mgr. Jana Bagiová, pôso-  
biaca v sektore s rýchloobrátkovým tovarom.

.....  
Juraj Bagi  
1. mája 2024

## Podakovanie

Chcel by som poďakovať svojmu vedúcemu Ing. Jaroslavovi Rozmanovi, PhD., za jeho čas a odbornú pomoc pri výskume. Ďalej by som rád poďakoval potravinárskej spoločnosti Starý Otec a.s. za ochotu poskytnúť údaje na výskum a, v neposlednom rade, Mgr. Jane Bagiovej za jej odborné znalosti a pomoc pri kategorizácii vstupných údajov.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>4</b>
<b>2</b>	<b>Rýchloobrátkový spotrebný tovar (Fast-moving consumer goods)</b>	<b>6</b>
2.1	Umelá inteligencia v odvetví s rýchloobratkovým tovarom . . . . .	7
2.2	Identifikácia kľúčových faktorov ovplyvňujúcich predaj tovaru . . . . .	8
<b>3</b>	<b>Súčasná riešenia problematiky</b>	<b>10</b>
3.1	Autoregresívny integrovaný kľzavý priemer . . . . .	11
3.2	Viacnásobná lineárna regresia . . . . .	12
3.3	Sezónny autoregresívny integrovaný pohyblivý priemer s lineárnou regresiou	12
<b>4</b>	<b>Umelé neurónové siete</b>	<b>14</b>
4.1	Predstavenie neurónových sietí . . . . .	14
4.2	Perceptron a aktivačná funkcia . . . . .	15
4.3	Neurónové siete a ich tréovanie . . . . .	15
4.4	Dopredné šírenie . . . . .	15
4.5	Spätne šírenie . . . . .	15
4.6	Epochy . . . . .	16
4.7	Rekurentné neurónove siete . . . . .	17
4.8	Long Short-Term Memory (Dlhodobá-Krátkodobá pamäť) . . . . .	19
4.9	LSTM vs. RNN . . . . .	21
4.10	Prehľad možných riešení problematiky pomocou umelej inteligencie . . . . .	22
4.10.1	Techniky UI . . . . .	22
4.10.2	Algoritmy . . . . .	23
4.11	Súčasný stav riešenia problematiky pomocou umelej inteligencie . . . . .	25
<b>5</b>	<b>Spracovanie dát</b>	<b>26</b>
5.1	Popis dátovej sady . . . . .	26
5.2	Spracovanie dátovej sady . . . . .	28
5.3	Reálne dáta a ich kategorizácia . . . . .	29
<b>6</b>	<b>Implementácia</b>	<b>31</b>
6.1	Python . . . . .	31
6.2	Implementácia v Pythone . . . . .	32

<b>7</b>	<b>Praktická časť</b>	<b>34</b>
7.1	Grafické zobrazenie vstupných faktorov . . . . .	34
7.2	Experiment č.1 . . . . .	36
7.2.1	Testovaný produkt Mrkváče (ID: 8) . . . . .	36
7.2.2	Testovaný produkt Klobásy (ID: 15) . . . . .	38
7.3	Experiment č.2 . . . . .	40
7.4	Experiment č.3 . . . . .	41
7.4.1	Testovaný produkt Šunka slovenska (ID: 1) . . . . .	42
7.4.2	Testovaný produkt Chlieb Dvojrnrko kvaskovy (ID: 3) . . . . .	43
<b>8</b>	<b>Vyhodnotenie výsledkov</b>	<b>44</b>
8.1	Vyhodnotenie výsledkov prognózy pre experiment č.1 . . . . .	44
8.1.1	Predikované a aktuálne dáta o predaji . . . . .	44
8.1.2	Kvantitatívne hodnotenie . . . . .	44
8.1.3	Praktické dôsledky presnosti predpovedí . . . . .	45
8.2	Vyhodnotenie výsledkov prognózy pre experiment č.2 . . . . .	46
8.3	Vyhodnotenie výsledkov prognózy pre experiment č.3 . . . . .	46
8.4	Porovnanie výsledkov s modelom aktuálne využívaného spoločnosťou . . . . .	46
8.5	Možnosti ďalšieho vývoja a vylepšení . . . . .	47
<b>9</b>	<b>Záver</b>	<b>48</b>
	<b>Literatúra</b>	<b>50</b>
<b>A</b>	<b>LSTM Keras</b>	<b>54</b>

# Zoznam obrázkov

2.1	Rýchloobrátkový tovar . . . . .	7
4.1	Umelá neurónová sieť [20] . . . . .	14
4.2	Perceptron Model (Minsky-Papert 1969) [16] . . . . .	15
4.3	Zjednodušený pohľad na gradientový zostup [19] . . . . .	16
4.4	Jedna epocha [42] . . . . .	17
4.5	Rekurentná neurónová sieť [27] . . . . .	17
4.6	Long Short-Term Memory [27] . . . . .	19
5.1	Normalizácia dát [15] . . . . .	28
7.1	Dážď, Sneh, Teplota . . . . .	34
7.2	Víkendy, Sviatky, Školské prázdniny . . . . .	35
7.3	Predaj, Priemer, Akcia (Mrkváče - 8) . . . . .	35
7.4	Predaj, Priemer, Akcia (Klobása Jablonická - 15) . . . . .	36
7.5	Strata a Validačná strata (Mrkváče - 8) . . . . .	37
7.6	Predikcie predajov (Mrkváče - 8) . . . . .	38
7.7	Strata a Validačná strata (Klobása Jablonická - 15) . . . . .	39
7.8	Predikcie predajov (Klobása Jablonická - 15) . . . . .	39
7.9	Predikcie predajov (Balene parky lahodkove - 2) . . . . .	40
7.10	Predikcie predajov (Roztek makovy plneny 250g - 9) . . . . .	41
7.11	Predikcie predajov (Tvaroh z Horehronia 250g - 5) . . . . .	41
7.12	Strata a Validačná strata (Spolu) . . . . .	42
7.13	Predikcie predajov (Šunka slovenská - 1) Aupark . . . . .	43
7.14	Predikcie predajov (Chlieb dvojzrnko 3) Aupark . . . . .	43

# Kapitola 1

## Úvod

V dnešnej konkurenčnej a dynamicky sa meniacej podnikateľskej klíme je predvídanie predaja kritickým faktorom úspechu v sektore rýchloobrátkového tovaru (FMCG). Rýchloobrátkový tovar [23], charakterizovaný krátkou dobou skladovania a vysokým objemom predaja, vyžaduje presné prognózy na optimalizáciu zásobovania. S vývojom technológií umelých neurónových sietí sa otvárajú nové možnosti spracovania veľkého množstva dát, predikcia predaja a následného efektívneho objednávanía tovaru v tomto sektore.

Cielom tejto bakalárskej práce je preskúmať a analyzovať efektívnosť umelých neurónových sietí v predvídaní predaja v sektore rýchloobrátkového tovaru. V rámci tejto práce budem venovať pozornosť procesu pedspracovania dát, návrhu a trénovaniu neurónovej siete ako aj optimalizačným technikám, ktoré môžu viesť k vylepšeniu výkonnosti predikcií. Práca taktiež poskytne prehľad o aktuálnom stave bádania v tejto oblasti, stanoví ciele a uvedie dôvody, prečo som si zvolil práve túto tému.

Predpovedanie predaja je kľúčovým nástrojom, ktorý prináša množstvo výhod a prínosov pre podniky v tomto odvetví. Presnejšie predpovede umožňujú firmám optimalizovať svoje zásoby, čím sa minimalizujú odpisy a to vedie k efektívnejšiemu využitiu financií a zníženiu nákladov. Rovnako umožňujú rýchlejšiu a efektívnejšiu reakciu na trhové zmeny a meniace sa spotrebiteľské preferencie, čím sa zvyšuje konkurencieschopnosť a schopnosť udržať krok s rýchlo sa meniacim trhom. Pri vývoji modelu je možné využiť niekoľko kľúčových prístupov na zlepšenie jeho výkonu a presnosti predikcií. Tieto optimalizácie zohľadňujú rôzne aspekty, od dátového spracovania, vytýčenia dôležitých faktorov, až po výber vhodnej architektúry modelu. Správna voľba architektúry modelu je kľúčová. Pre FMCG predpovede môže byť vhodná niektorá z RNN architektúr, ktorá dokáže efektívne zohľadniť časové závislosti.

Rekurentné neurónové siete (RNN) [21] sú dobrým nástrojom na predikciu predaja v sektore FMCG, pretože dokážu efektívne zohľadniť časové závislosti a vzťahy medzi predchádzajúcimi a súčasnými udalosťami. RNN fungujú na základe schopnosti udržiavať vnútorný stav alebo pamätať si informáciu o predchádzajúcich dátach. Toto je zásadný prvok pre predikciu v sektore FMCG, pretože predaj, frekvencia objednávanía a objednané množstvá môžu byť významne ovplyvnené predchádzajúcimi dátami. Pre zlepšenie predikcií predaja využijeme históriu predajov za posledných  $n$  dní/období ako vstupné dáta pre RNN. Tieto dáta budú poskytovať cenné informácie o trendoch a sezónnostiach v predaji.

Podľa existujúcej literatúry sa predikcia dopytu v priemysle FMCG stáva stredobodom intenzívneho výskumu. V súčasnosti existuje aktívny výskumný záujem o efektívne metódy predpovedania dopytu, pričom sa pozornosť venuje najmä využitiu umelej inteligencie. Medzi najčastejšie prístupy patrí využívanie neurónových sietí s vrstvami LSTM



(Long Short-Term Memory)[4], ktoré ukázali najlepšiu prediktívnu schopnosť pre rôzne typy rýchlo rotujúcich spotrebiteľských tovarov. Tieto modely sú schopné účinne extrahovať informácie zo surových dát a poskytujú výrazne presnejšie predpovede dopytu v porovnaní s tradičnými metódami. Zároveň je však potrebné podotknúť, že v rámci súčasného bádania sa ešte stále venuje pozornosť možnosti zlepšenia predpovedania dopytu v danom sektore.

Podľa existujúcich výskumov sa predikcia dopytu v priemysle FMCG stáva stredobodom intenzívneho výskumu. V práci pána José Nicolaás Valbuena Godoya [17] bol predstavený komplexný porovnávací výskum rôznych modelov predpovedania dopytu so zameraním na rýchlo rotujúci spotrebný tovar. Zistenia naznačili, že RNN, najmä tie s dvoma LSTM vrstvami, prebehli ostatné skúmané modely a preukázali ich nadradenú prediktívnu schopnosť. Okrem toho náročná povaha týždenných časových radov pre štyri produkty zdôraznila obmedzenia klasických a stochastických modelov a zdôraznila potrebu pokročilejších prístupov ako sú RNN. Vzhľadom na tieto zistenia som sa rozhodol adresovať problém predpovedania dopytu pomocou rekurentných neurónových sietí (RNNs).

## Kapitola 2

# Rýchloobrátkový spotrebný tovar (Fast-moving consumer goods)

FMCG [22, 23] alebo rýchloobrátkový spotrebný tovar (z angl. Fast-Moving Consumer Goods) predstavuje širokú kategóriu výrobkov, ktoré majú vysoký dopyt, rýchlo sa predávajú a majú dostupnú cenu. Tieto produkty majú sklon rýchlo opúšťať regály obchodov a supermarketov, pretože spotrebitelia ich pravidelne kupujú a takmer denne využívajú. Do kategórie FMCG patria rôzne druhy výrobkov vrátane potravín, hygienických potrieb, nápojov, písacích potrieb, voľnopredajných liekov, čističov a pracích prostriedkov, plastového tovaru, výrobkov osobnej starostlivosti, ale aj cenovo dostupnej spotrebnej elektroniky, ako sú mobilné telefóny a slúchadlá. Tieto produkty sú neoddeliteľnou súčasťou každodenného života a ich dopyt je stabilný a konzistentný. Rýchloobrátkový spotrebný tovar tvorí dôležitú časť ekonomiky a má významný vplyv na obchodné operácie a spotrebné návyky. Predstavuje dynamický segment trhu, kde konkurencia je vysoká a inovácie, marketing a distribúcia hrajú kľúčovú úlohu v získavaní zákazníkov.

Kritériá pre klasifikáciu tovarov v odvetví FMCG zahŕňajú perspektívy spotrebiteľa a marketingu:

Kritériá, ktoré vyhodnocuje spotrebiteľ pri nákupe rýchloobrátkového tovaru:

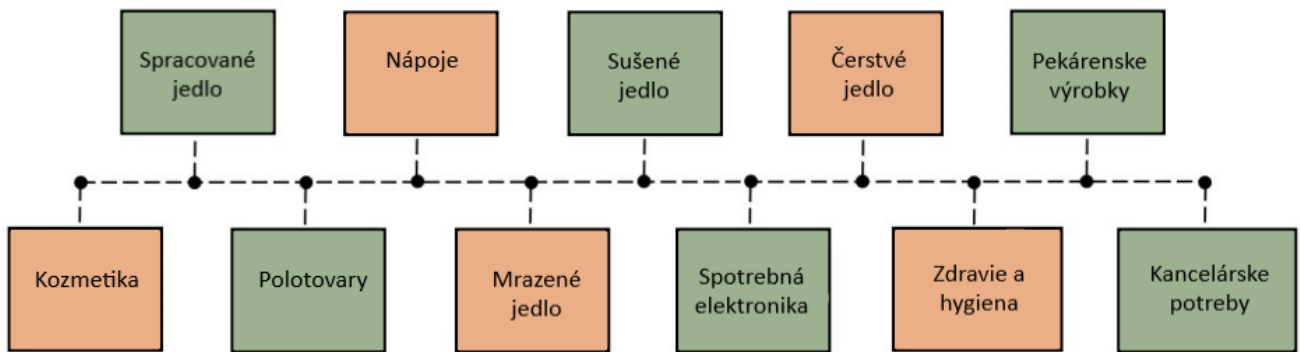
- Časté nákupy
- Minimálne úsilie pri výbere produktov
- Rozumná cena
- Životnosť produktu
- Rýchla spotreba

Z marketingového hľadiska sú pri aktivitách kľúčové nasledovné body:

- Vysoké opakované nákupy zo strany spotrebiteľa
- Nízky zisk z jedného produktu
- Krátka životnosť produktu
- Konkurencieschopná cena produktu
- Viacero distribučných kanálov na všetkých úrovniach

- Výrobca neposkytuje produkt priamo koncovému spotrebiteľovi
- Zväčša pomerne saturovaný trh

Medzi popredné spoločnosti [40] FMCG patria Procter & Gamble, Johnson & Johnson, Nestle, Unilever, JBS, L'Oréal spolu s nápojovými spoločnosťami ako Coca Cola, Pepsi atď. Zoznam je zostavený na základe troch hlavných parametrov, ako sú príjmy, zisk a množstvo celosevtovo distribuovaných brendov.



Obr. 2.1: Rýchloobrátkový tovar

## 2.1 Umelá inteligencia v odvetví s rýchloobrátkovým tovarom

Firmy často čelia rôznym problémom s objednávaním tovaru v odvetví FMCG z dôvodu rýchleho tempa a vysokého objemu predaja a preto integrácia umelej inteligencie v tomto odvetví prináša nesmierne výhody. Vďaka schopnosti analyzovať obrovské množstvo dát môže predpovedať spotrebu s neuveriteľnou presnosťou. Týmto spôsobom podniky môžu:

- Presnejšie predvídať dopyt: Umelá inteligencia môže analyzovať historické dáta, sezónne vzory a iné faktory, aby predvídala budúci dopyt s vysokou presnosťou. Toto zlepšené predvídanie môže slúžiť ako základ pre efektívnejšie rozhodovanie v oblasti výroby a nákupu.
- Optimalizovať výrobu a nákup: Na základe predpovedí od umelej inteligencie môžu firmy plánovať svoju výrobu a nákupy tak, aby sa minimalizovali nadmerné zásoby alebo nedostatok tovaru. Týmto spôsobom môžu dosiahnuť vyššiu efektivitu a ziskovosť.
- Reagovať rýchlejšie na zmeny dopytu: Umelá inteligencia môže detegovať náhle zmeny v spotrebe a umožniť rýchlejšiu reakciu. To môže zahŕňať prispôbovanie výrobných plánov alebo zmeny v nákupných stratégiách v reálnom čase.
- Minimalizovať sklady a plytvanie zdrojmi: S presnejšími predpovedami dopytu môžu firmy minimalizovať zásoby a zabraňovať plytvaniu zdrojmi na nevyužité produkty.
- Zlepšiť zákaznícku spokojnosť: Predpovedanie dopytu umožňuje lepšie plánovať dodávky, čo môže viesť k lepšej spokojnosti zákazníkov a vyššiemu podielu spätných nákupov.

## 2.2 Identifikácia kľúčových faktorov ovplyvňujúcich predaj tovaru

Rozpoznanie a pochopenie týchto faktorov je kľúčové pre úspešné riadenie predaja v odvetví FMCG.

Na základe praxe Mgr. Jany Bagiovej, ktorá má viacročné skúsenosti v odvetví FMCG a zameriava sa aj na procesy objednávanía tovaru, boli identifikované kľúčové faktory, ktoré ovplyvňujú efektívnosť objednávanía a predaja FMCG. Tieto faktory zahŕňajú:

1. **Vyhodnotenie minulosti:** Analýza predchádzajúcich predajov umožňuje odhadnúť budúci dopyt na základe historických dát a trendov. Čím väčší máme rozsah dát, ktoré vieme analyzovať tým presnejšia môže byť predpoveď. V súčasnosti nie je v ľudských silách a ani v bežne používaných softvérových riešeniach spracovávať rýchlo a efektívne dáta z viacerých rokov a súčasne vyhodnocovať všetky aktuálne faktory ovplyvňujúce spotrebu.
2. **Poddimezovanie objednávky:** Nedostatočné množstvo objednaného tovaru vedie k strate z ušlého zisku z predaja a zo sklamanía zákazníka, ktorý sa už nemusí do predajne vrátiť a opakovane nakúpiť.
3. **Obrátka v predajniach a združovanie objednávok:** Združovanie malých objednávok z viacerých predajní znižuje logistické náklady a napomáha pokryť neočakávané výpadky tovaru v predajniach. Kľúčové je nielen objednané množstvo, ale aj správne načasovanie logistiky od dodania tovaru dodávateľom po doručenie na miesto predaja.
4. **Vplyv počasia, sviatkov, sezóny, zatvorenia obchodov:** Tieto faktory výrazne ovplyvňujú správanie zákazníkov a teda aj samotné objednávanie tovaru. Správny odhad miery vplyvu týchto faktorov je extrémne kľúčový pre optimálne zásobovanie predajní.
5. **Dodanie/nedodanie substitučných produktov:** Nedostatok alternatívnych produktov môže zvýšiť dopyt po hlavnom produkte a naopak.
6. **Dodanie toho istého produktu od rôznych dodávateľov:** Rôzni dodávatelia môžu mať odlišné dodacie lehoty a kvalitu, čo ovplyvňuje dostupnosť tovaru.
7. **Odpisy:** Správne vyhodnotenú odpisy minimalizujú stratu z produktov po záručnej dobe a tak zvyšujú čistú maržu z predaja.
8. **Tovar nesprávne dodaný:** Nesprávne dodaný tovar môže viesť k nespokojnosti zákazníkov a strate predaja a v prípade ak o takejto situácii nie je včasná vedomosť môže skresliť nasledujúce objednávanie tovaru.
9. **Komplementárnosť/doplňujúcich produktov:** Ponúkание produktov, ktoré sa dopĺňajú, môže zvýšiť celkový predaj.
10. **Akcie tovarov/marketing:** Marketingové opatrenia a akcie môžu zvýšiť povedomie o produkte a viesť k vyšším predajom. Zároveň však v budúcnosti pri objednávaní tovaru treba myslieť na to, že zvýšený predaj bol spôsobený práve marketingovou aktivitou.

11. **Čas do vypredania produktu:** Predpovedanie, ako rýchlo sa produkt vypredá, umožňuje lepšie plánovať dodávky a minimalizovať sklady. Včasná Informácia o blížiacom sa konci záruky tovaru je kľúčová pre prípadné plánovanie aktivít na podporu predaja. A súčasne včasná informácia o blížiacom sa konci záruky tovaru je kľúčová pre prípadné plánovanie aktivít na podporu "vypredania skladov".
12. **Hustota konkurenčných predajní:** Keďže trh FMCG je pomerne saturovaný, je dôsledná informácia o konkurenčnom prostredí kľúčová, predovšetkým pri rozhodovaní o lokácii predajne. Ale aj počas existencie je dôležité monitorovať konkurenčné prostredie a vyhodnocovať viacero faktrov napr. retailové ceny, veľkoobchodné ceny, marketingové aktivity, šírku sortimentu,...
13. **Frekvencia objednávania:** Optimálna frekvencia objednávania minimalizuje skladovacie náklady, maximalizuje dostupnosť produktu a napomáha k pružnej reakcii na akýkoľvek výkyv v dopyte produktu. A v neposlednom rade je čerstvosť predovšetkým pri FMCG produktoch jeden z najčastejších faktorov ovplyvňujúcich nákupné rozhodovanie.
14. **Trvanlivosť produktu a veľkosť balení:** Dôležité pre predaj produktov s obmedzenou životnosťou.
15. **Veľkosť skladovacích priestorov:** Správne dimenzované sklady minimalizujú skladovacie náklady a zabezpečujú správnu dostupnosť tovaru.

## Kapitola 3

# SúčasnÉ riešenia problematiky

Z výsledkov výskumu v práci "Demand forecasting in retail grocery stores in the Czech Republic" [3] vyplýva, že väčšina maloobchodných predajní (91 %) vytvára vlastné predpovede dopytu, ktoré používajú na podporu rozhodovania pri riadení a doplňovaní zásob v maloobchodnom podnikaní. Ostatní respondenti, ktorí nepredpovedajú dopyt, najčastejšie doplňujú zásoby na základe tržieb z minulých predajov alebo pracujú s predpoveďami prijatými od centrály maloobchodného reťazca. Vzhľadom na to, že výskum bol zameraný na metódu predpovedania dopytu v maloobchode, títo respondenti boli z ďalšej časti prieskumu vylúčení.

V ďalšej časti výskumu si respondenti vybrali ľubovoľný počet dostupných metód, ktoré sa používajú pri predpovedaní dopytu v maloobchode. Možnosť špecifikovať odlišnú metódu predpovedania, ktorá sa nenachádzala v zozname nevyužil žiaden z respondentov. Maloobchodné podniky jasne uprednostňujú metódu založenú na úsudku (názory predajcov), ktorá sa používa pri predpovedaní takmer všetkými respondentmi (94 %). Takmer polovica respondentov sa tiež spolieha na naivnú metódu alebo na priemer z hodnôt minulých predajov. S výnimkou metódy očakávaní zákazníkov sa ostatné metódy predpovedania v maloobchodných predajniach používajú zriedka a žiadna z metód pokročilej analýzy časových radov nebola respondentmi označená.

Z výsledkov výskumu tiež vyplýva, že maloobchodné predajne si uvedomujú, že zmena ceny a sezónnosť produktov významne ovplyvňujú dopyt, ale vo väčšine prípadov nepoužívajú adekvátne metódy predpovedania (jednoduchá regresia, exponenciálne vyhladzovanie, dekompozícia časových radov alebo iné techniky analýzy časových radov) na kvantifikáciu vplyvu týchto faktorov na dopyt po potravinách, ale zvyčajne len kvalitatívne odhady v kombinácii s naivnými a priemernými metódami. Tieto jednoduché štatistické odhady sú však použiteľné len pri predpovedaní vývoja časových radov tržieb, ktoré nie sú narušené trendom, meniacimi sa cenami produktov a sezónnymi kolísaniami.

V súčasnej dobe poznáme niekoľko prístupov k predpovedaniu podnikových predajov [41], pričom každý smeruje k optimalizácii obchodných procesov a zvyšovaniu efektívnosti podnikateľských rozhodnutí. Tieto prístupy zahŕňajú trendovú analýzu, regresnú analýzu, analýzu časových radov, príčinnú analýzu, ako aj pokročilejšie štatistické modely, ako je ARIMA a MLR.

**Trendová analýza** Definícia: Analyzovanie minulých dát o predaji na identifikáciu vzorov v rôznych kategóriách, ako sú sezónnosť, lokalita alebo cieľová skupina. Účel: Vytváranie predpovedí o príjmoch a sledovanie potenciálnych zmien vo výkonnosti. Proces: Firmy

využívajú poznatky z trendovej analýzy na vytváranie fundovaných predpovedí a odhadov týkajúcich sa rôznych obchodných segmentov, čím im umožňujú prispôbiť stratégie pre budúce výsledky.

**Regresná analýza:** Definícia: Skúmanie, ako individuálne stratégie predaja (nezávislá premenná) ovplyvňujú výkon (závislá premenná) v čase s využitím dát o minulom výkone na predpovedanie výsledkov. Účel: Získanie hlbšieho porozumenia výkonnosti predaja na podrobnej úrovni. Proces: Vyžaduje si jasný pohľad na vnútorné a vonkajšie faktory ovplyvňujúce predaj. Merateľné premenné sú hodnotené v čase na vytvorenie presnej predpovede.

**Analýza časových radov:** Definícia: Používanie dát získaných v rôznych časových intervaloch na sledovanie zmien v čase a predpovedanie vzorov v sezónach, cykloch a trendoch. Účel: Vytváranie nových stratégií predaja, určovanie pravdepodobnosti výsledkov a pochopenie príčin predpovedaných výsledkov. Proces: Konzistentné zaznamenávanie dát o predaji je nevyhnutné. Aplikácie zahŕňajú stanovenie cien tovarov ovplyvnených nedostatkami od dodávateľov a zohľadnenie anomálií v príjmoch pre plánovanie stratégií budúceho predaja.

**Príčinná analýza:** Definícia: Hodnotenie a predpovedanie, ako budú fluktuácie na trhu ovplyvňovať zisky spoločnosti, identifikácia faktorov ovplyvňujúcich smer trhu. Účel: Vytváranie stratégií a plánov na predvídateľnú budúcnosť, vytváranie modelov predaja a reklamy pre ciele odolné voči budúcnosti. Proces: Začína posúdením súčasného stavu trhu a identifikáciou nezávislých a závislých faktorov. Pomáha predajným tímom pripraviť sa na očakávaný dopyt počas období nízkeho a vysokého rastu.

### 3.1 Autoregresívny integrovaný kĺzavý priemer

ARIMA [9, 26] je štatistická metóda používaná na modelovanie časových radov a predikciu budúcich hodnôt. Táto metóda kombinuje tri hlavné komponenty:

1. **Autoregresia (AR):** Táto časť modelu zahŕňa regresiu aktuálnych hodnôt časovej rady na predchádzajúce hodnoty v tejto rade, zachytáva vzťah medzi aktuálnym a predošlými pozorovaniami. Máme  $AR(p)$ , kde 'p' je počet predchádzajúcich hodnôt, poradie autoregresívnej časti.
2. **Integrácia (I):** Táto časť sa týka integrácie časovej rady, čo znamená prevod pôvodných dát na rozdiely medzi hodnotami (prvé diferencie). To sa robí s cieľom odstrániť sezónne trendy alebo nesúlady v dátach a doceliť ustálenosť časovej rady. Označenie  $I(d)$ , kde 'd' je poradie diferencovania.
3. **Kĺzavý priemer (MA):** Modeluje vzťah medzi jedným pozorovaním a reziduálnou chybou z modelu pohyblivého priemeru, aplikovaného na oneskorené pozorovania. Označenie  $MA(q)$ , kde 'q' je počet predchádzajúcich hodnôt chyby, poradie pohyblivého priemeru.

Aj táto metóda sa využíva na predikciu predajov a optimalizáciu objednávok. Analyzuje historické údaje o predaji, identifikuje vzory a sezónnosť a následne trénuje model ARIMA. Po validácii modelu je možné predikovať budúce hodnoty predaja, čo sa využíva v objednávkovom systéme pre generovanie optimálnych objednávok podľa predpovedaného dopytu. Aj keď je to účinný nástroj, nie je schopný dobre modelovať komplexné nelineárne vzory a je citlivý na vybočujúce hodnoty. Požaduje stacionárne dáta a jeho presnosť môže

byť ovplyvnená sezónnymi vzormi. Nastavenie optimálnych parametrov vyžaduje skúsenosti, a v dlhodobom horizonte môže byť menej presná. Často sa používa pre krátkodobé predpovede a jeho lineárna povaha nie je vhodná pre všetky typy vzťahov v dátach.

## 3.2 Viacnásobná lineárna regresia

VLR [18] využíva niekoľko vysvetľujúcich premenných na predpovedanie výsledku. Cieľom je modelovať lineárny vzťah medzi vysvetľujúcimi (nezávislými) premennými a výslednými (závislými) premennými. V praxi to znamená, že VLR sa snaží identifikovať a kvantifikovať vzťahy medzi viacerými faktormi a výslednou premennou. Táto technika je užitočná v situáciách, kde existuje podozrenie, že viaceré premenné môžu ovplyvniť výsledok, a jej cieľom je nájsť optimálny model, ktorý môže predpovedať hodnoty výslednej premennej na základe kombinácie vysvetľujúcich premenných.

Vzorec viacnásobnej linearnej regresie:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon$$

$y_i$  je závislá premenná (dependent variable),

$x_{i1}, x_{i2}, \dots, x_{ip}$  sú vysvetľujúce premenné (explanatory variables), (3.1)

$\beta_0$  je y-odhad (y-intercept alebo konštantný term),

$\beta_1, \beta_2, \dots, \beta_p$  sú koeficienty sklonu pre každú vysvetľujúcu premennú,

$\epsilon$  je chyba modelu, známa tiež ako reziduála.

Spájanie VLR s predikciami v odvetví FMCG poskytuje podnikom nástroj na lepšie pochopenie faktorov ovplyvňujúcich predaj a vytváranie presnejších a efektívnejších obchodných stratégií. Je však dôležité si byť vedomý obmedzení VLR, v niektorých prípadoch môže byť vhodné použiť pokročilejšie metódy, najmä ak dáta obsahujú nelineárne vzťahy alebo sú nezávislé premenné príliš závislé jedna od druhej.

## 3.3 Sezónny autoregresívny integrovaný pohyblivý priemer s lineárnou regresiou

SARIMA-MLR [17] je kombinovaný prístup, ktorý zahŕňa metódu Seasonal AutoRegressive Integrated Moving Average (SARIMA) a Multiple Linear Regression (MLR). Tento model umožňuje efektívne zvládanie sezónnych fluktuácií pomocou SARIMA a zároveň pridáva flexibilitu prostredníctvom MLR, ktorý zohľadňuje ďalšie vplyvy.

1. **Predikcia pomocou SARIMA:** Použitie modelu SARIMA na predikciu časových radov a sezónnych vzorov.
2. **Identifikácia ďalších vplyvov:** Použitie MLR na identifikáciu a modelovanie vplyvov dodatočných premenných, ktoré môžu ovplyvniť predaj.
3. **Kombinácia predikcií:** Kombinácia predikcií z oboch modelov tak, aby výsledný model zohľadňoval časovú závislosť a doplnkové faktory.



4. **Optimalizácia váh a koeficientov:** Prispôsobenie váh a koeficientov v modeli tak, aby sa dosiahlo najlepšie možné prediktívne výkonosť.

SARIMA-MLR môže byť vhodným riešením v prípade, keď časové rady sú ovplyvňované rôznymi faktormi, vrátane sezónnych a dodatočných nečasových vplyvov. Kombinovaním týchto dvoch metód môže byť dosiahnutá lepšia presnosť predikcií a robustnejšie modelovanie komplexných dátových vzorov. Tieto hybridné modely(SARIMA-MLR/-QR)[6] majú nádejné využitie v potravinovom maloobchode, kde pomáhajú minimalizovať plytvanie potravín a nedostatky skladov. Tento prístup k predpovedaniu je užitočný najmä v prostredí s vysokou volatilitou predajov, ako je FMCG, kde sezónne trendy a iné faktory často menia dopyt a predajové vzory.

História a vývoj týchto metód svedčia o ich dôležitosti v predpovedaní predaja. Ale vzhľadom na ich obmedzenia, najmä v prípade komplexných dátových vzorov a rýchlo meniacich sa trhových podmienok, sa ukazuje potreba prechodu k sofistikovanejším prístupom. Tieto tradičné metódy poskytujú pevný základ a sú užitočné v určitých scenároch, ale v súčasnej dobe sa stávajú doplnujúcimi k pokročilejším modelom založeným na strojovom učení.


## Kapitola 4

# Umelé neurónové siete

Vo výpočtovej technike je neurónová sieť program alebo systém, ktorý je modelovaný na ľudskom mozgu a je navrhnutý tak, aby napodobňoval spôsob fungovania mozgu, najmä proces učenia (prebrané z "Collins English Dictionary"[2]). Neurónové siete sú v súčasnosti považované za jeden z najlepších algoritmov strojového učenia. Ich sila spočíva v schopnosti extrahovať zložité vzorce a vzťahy zo vstupných dát, vďaka čomu dokážu priniesť výsledky s veľkou presnosťou. Zjednodušene fungujú tak, že vytvoríme model, ktorý natrénujeme na čo najväčšom množstve dát, na základe čoho dokážu poskytnúť výsledky nových neznámych prípadov.

### 4.1 Predstavenie neurónových sietí

Neurónová sieť [31] pozostáva z viacerých vrstiev neurónov, ktoré sú vzájomne prepojené. To znamená, že neurón v sieti je spojený s neurónom v predchádzajúcej a nasledujúcej vrstve, pričom prepojenia medzi neurónmi majú svoje ohodnotenia a prah. Ak je výstup ktoréhokoľvek jednotlivého uzla nad špecifikovanou prahovou hodnotou, tento uzol sa aktivuje a odosiela dáta do ďalšej vrstvy siete. Tieto neuróny sú potom usporadúvané do vrstiev. Spravidla jednej vstupnej, jednej výstupnej vrstvy a niekoľko skrytých vrstiev. Určujúce pre účinnosť neurónových sietí je ich schopnosť učiť sa a zdokonaľovať na základe sady trénovacích dát. Proces učenia má za cieľ zminimalizovať chyby v predikciách a zároveň dosiahnuť schopnosť generalizovať na nové, nepoznané dáta.




Obr. 4.1: Umelá neurónová sieť [20]

## 4.2 Perceptron a aktivačná funkcia

Perceptron [37] je základnou jednotkou neurónovej siete, môžeme ho chápať ako stavebnú jednotku, ktorá prijíma niekoľko vstupov a poskytuje jeden výstup. Skladá sa zo štyroch rozdielnych blokov: vstupné hodnoty, váhy a prah, aktivačná funkcia a výstupná hodnota. Reprezentácia vstupu vyzerá takto:

$$w_1x_1 + w_2x_2 + w_3x_3 + 1b \quad (4.1)$$

kde  $x$  označuje vstupnú hodnotu,  $w$  váhy a  $b$  prah spojenia. Ale toto platí len ak sa rozprávame o lineárnych transformáciách. Pokiaľ ide o tie nelineárne, musíme počítať s aktivačnou funkciou, ktorá berie súčet váženého vstupu ako argument a vráti výstup neurónu. V súčasnosti poznáme niekoľko aktivačných funkcií ako: Sigmoid, Tanh, ReLu, ale aj mnoho ďalších.



Obr. 4.2: Perceptron Model (Minsky-Papert 1969) [16]

## 4.3 Neurónové siete a ich tréovanie

V tejto kapitole sú popísané dôležité aspekty tréovania neurónových sietí ako procesy dopredného a spätného šírenia [42], ktoré sú kľúčovými krokmi pri učení neurónových sietí. Nasledujúca časť je prebraná z kurzu o hlbokom učení [36].


## 4.4 Dopredné šírenie

Ako už názov vypovedá, vstupné dáta sú privádzané v smere dopredu. Každá skrytá vrstva prijíma vstupné dáta, spracováva ich podľa aktivačnej funkcie a posúva do nasledujúcej vrstvy. Tak ako je popísaná funkčnosť perceptronu vyššie, tak každý neurón sa spracováva v dvoch krokoch. Prvé sa vypočíta vážený súčet vstupov, ktorý je následne argumentom aktivačnej funkcie, na základe ktorej neurón rozhodne, či informáciu poslať ďalej alebo nie.

## 4.5 Spätné šírenie

Po dokončení dopredného šírenia sa výstupy siete porovnávajú s očakávanými hodnotami. Rozdiel medzi týmito hodnotami sa označuje ako chyba, ktorá vznikla pri predikcii neurónovej siete. Na to aby sme dokázali zlepšiť presnosť predikcie, zavádzame takzvané spätné šírenie, kde nastáva reálne učenie. Tento proces využíva gradientový zostup [34, 12] a derivácie chybovej funkcie vzhľadom na váhy siete na úpravu váh tak, aby sa dosiahol lepší výkon siete. Gradientový zostup je spôsob, ako aktualizovať váhy neurónov s minimalizáciou stratovej funkcie. Pomocou tejto metódy sa učí, ako rýchlo a efektívne spočítať

hodnotu stratovej funkcie tak, aby rozdiel medzi skutočnými a očakávanými výstupmi bol čo najmenší.



Obr. 4.3: Zjednodušený pohľad na gradientový zostup [19]

Zjednodušené riešenie:

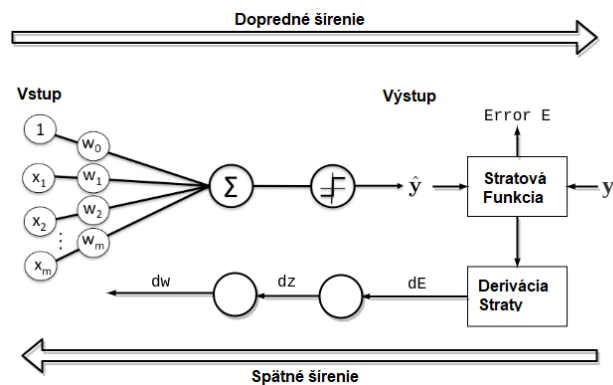
- Výpočet sklonu v aktuálnom bode
- Ak je sklon negatívny, posun vpravo
- Ak je sklon pozitívny, posun vľavo
- Kroky sa opakujú, kým sklon nie je rovný 0

Ale aj pri metódach ako je táto sa stretávame s problémom keď sa gradient môže ľahko zaseknúť v lokálnom minime, čo môže narušiť celý proces učenia. A preto sa v praxi využívajú sofistikovanejšie modely ako stochastický gradientový zostup alebo „mini-batch Gradient Descent“. Tieto metódy využívajú náhodný výber malých podmnožín tréningových dát alebo „mini-batches“. Týmto spôsobom sa aktualizujú váhy v sieti častejšie, čo môže pomôcť uniknúť z lokálnych miním a to prispieva k rýchlejšiemu konvergovaniu ku globálnemu minimu. Taktiež to znižuje výpočtovú záťaž a umožňuje rýchlejšie tréningovanie siete.

A teda spätná propagácia je proces, ktorým sa neurónová sieť učí a zahŕňa aktualizáciu váh neurónov po výpočte stratovej funkcie. Tento proces umožňuje zlepšiť schopnosti predikcie tým, že sa učí z chýb, ktoré robí v predchádzajúcich predikciách. Je dôležité spomenúť, že spätná propagácia aktualizuje váhy všetkých neurónov v sieti súčasne. Na začiatku tréningu sa váhy neurónov inicializujú náhodnými malými hodnotami. Postupom učenia a spätného šírenia sú tieto váhy postupne upravované na zmysluplné hodnoty, čo pomáha sieti dosahovať lepšie výsledky pri predikciách.

## 4.6 Epochy

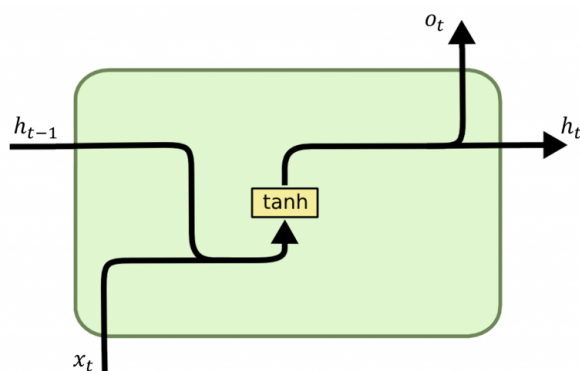
Epocha [7] znamená tréningovanie neurónovej siete so všetkými tréningovými dátami pre jeden cyklus. V jednej epoche používame všetky údaje presne raz. Dopredné a spätné šírenie sa rátať ako jeden prechod:



Obr. 4.4: Jedna epocha [42]

## 4.7 Rekurentné neurónove siete

Rekurentná neurónová sieť (RNN) [21] je špeciálny typ umelej neurónovej siete, ktorá sa špecializuje na spracovanie postupností alebo časových radov. Tieto učiace algoritmy sú často využívané pri problémoch, kde je dôležitá časová závislosť. Na rozdiel od bežných neurónových sietí, ktoré predpokladajú, že vstupy a výstupy sú nezávislé, RNN berie do úvahy predchádzajúce hodnoty v postupnosti, čo umožňuje lepšie predikcie aktuálnych hodnôt. Ďalšou dôležitou vlastnosťou RNN je, že majú spoločné váhové parametre medzi všetkými vrstvami siete. To umožňuje konzistentné upravovanie váh počas učenia a spätného šírenia chyby. RNN používajú špecifický algoritmus spätného šírenia v čase (BPTT)[8], ktorý je určený pre sekvenčné dáta. Jeho princípy sú podobné tradičnému spätnému šíreniu, ale BPTT zahŕňa sčítanie chýb v každom kroku časovej sekvencie.



$x_t$  : vstupný vektor ( $m \times 1$ ).  
 $h_t$  : vektor skrytej vrstvy ( $n \times 1$ ).  
 $o_t$  : výstupný vektor ( $n \times 1$ ).  
 $b_h$  : vektor sklonu ( $n \times 1$ ).  
 $U, W$  : matice parametrov ( $n \times m$ ).  
 $V$  : matica parametrov ( $n \times n$ ).  
 $\sigma_h, \sigma_y$  : aktivačné funkcie.

Obr. 4.5: Rekurentná neurónová sieť [27]

Dopredná propagácia:

$$\begin{aligned} h_t &= \sigma_h(i_t) = \sigma_h(U_h x_t + V_h h_{t-1} + b_h) \\ y_t &= \sigma_y(a_t) = \sigma_y(W_y h_t + b_h) \end{aligned} \quad (4.2)$$

kde:

- $h_t$ : Skrytý stav na čase  $t$ .
- $\sigma_h$ : Aktivačná funkcia pre skrytý stav.

- $i_t$ : Vstupný vektor na čase  $t$ .
- $x_t$ : Vstupný vektor na čase  $t$ .
- $U_h, V_h, b_h$ : Parametre pre výpočet skrytého stavu.
- $y_t$ : Výstup na čase  $t$ .
- $\sigma_y$ : Aktivačná funkcia pre výstup.
- $a_t$ : Lineárna kombinácia skrytého stavu pre výpočet výstupu.
- $W_y, b_y$ : Parametre pre výpočet výstupu.

Spätná propagácia:

$$\begin{aligned}
\Pi_t &= \frac{\partial E_t}{\partial o_t} \frac{\partial o_t}{\partial h_t} + \frac{\partial h_{t+1}}{\partial h_t} \Pi_{t+1} \\
\beta_t^U &= \beta_{t+1}^U + \Pi_t \frac{\partial h_t}{\partial U_t} \\
\beta_t^V &= \beta_{t+1}^V + \Pi_t \frac{\partial h_t}{\partial V_t} \\
\beta_t^W &= \beta_{t+1}^W + \frac{\partial E_t}{\partial o_t} \frac{\partial o_t}{\partial W_t} \\
\frac{\partial E}{\partial X} &\equiv \beta_0^x
\end{aligned} \tag{4.3}$$


kde:

- $\Pi_t$ : Rekurzívny term pre spätnú propagáciu chyby vzhľadom k skrytému stavu  $h_t$ .
- $\beta_t^U$ : Aktualizovaný parameter váh  $U_h$ .
- $\beta_t^V$ : Aktualizovaný parameter váh  $V_h$ .
- $\beta_t^W$ : Aktualizovaný parameter váh  $W_y$ .
- $\frac{\partial E}{\partial X}$ : Parciálna derivácia chyby vzhľadom k vstupu  $X$ .

Aj napriek svojim výhodám, RNN majú svoje obmedzenia [38]. Jedným z takýchto obmedzení je problém dlhých závislostí. Pri spracovaní veľmi dlhých postupností môžu RNN mať problémy s uchovaním informácií z počiatočných krokov v sekvencii. Tento jav je spôsobený tým, že gradient stratovej funkcie môže buď príliš rýchlo klesnúť na nulu alebo príliš rýchlo narastať, čo vedie k strate informácií. Toto je definované tým, ako rýchlo sa mení sklon stratovej funkcie vzhľadom na chybovú krivku. Ak je sklon príliš malý, parametre váh sa neustále menia a aktualizujú, až kým nedosiahnu hodnotu blízku nule. Vtedy sa algoritmus prestane učiť. Na druhej strane, explodujúce prechody nastávajú, keď je prechod príliš veľký, čo vedie k nestabilnému modelu. V takom prípade budú hodnoty váh v modeli príliš veľké a nakoniec budú reprezentované ako NaN (Not a Number). Preto boli vyvinuté varianty RNN, ktoré sú navrhnuté tak, aby tento problém riešili. Medzi najznámejšie patrí LSTM (Long Short-Term Memory) a GRU (Gated Recurrent Unit).

## 4.8 Long Short-Term Memory (Dlhodobá-Krátkodobá pamäť)

LSTM [4] je typ rekurentnej neurónovej siete, ktorá je schopná spracovávať časové sekvencie dát a zároveň je schopná sa naučiť dlhodobé závislosti medzi nimi. Naopak tradičné RNN majú jediný skrytý stav, čo vedie k problémom s dlhodobými závislosťami. LSTM rieši problém uchovávaní dlhodobých informácií v rekurentných neurónových sieťach tým, že zavádza špeciálnu pamäťovú bunku. Táto bunka funguje ako úložisko na uchovávanie dôležitých informácií na dlhší časový úsek. Riadi sa tromi bránami: vstupnou bránou, bránou zabudnutia a výstupnou bránou. Vstupná brána kontroluje, aké nové informácie majú byť pridané do pamätej bunky. Brána zabudnutia určuje, ktoré staré informácie majú byť vymazané z pamätej bunky. Výstupná brána rozhoduje, ktoré informácie sa majú v danej chvíli použiť z pamätej bunky. Týmto spôsobom má LSTM kontrolu nad tým, aké informácie sú dôležité a ako s nimi pracovať, čo umožňuje sieťam naučiť sa dlhodobé závislosti v dátach.



Obr. 4.6: Long Short-Term Memory [27]

Dopredná propagácia:

$$\begin{aligned}
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\
 o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\
 \tilde{C}_t &= \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\
 C_t &= f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \\
 h_t &= o_t \odot \tanh(C_t)
 \end{aligned} \tag{4.4}$$

kde:

- $f_t$ : Výstup brány zabudnutia, ktorý kontroluje, koľko informácií sa má zabudnúť z minulého stavu  $C_{t-1}$ .
- $i_t$ : Výstup vstupnej brány, ktorý kontroluje, koľko nových informácií sa má pridať k stavu pamäte.
- $o_t$ : Výstup výstupnej brány, ktorý reguluje, koľko informácií sa má odovzdať výstupu.
- $\tilde{C}_t$ : Nová kandidátka hodnota stavu pamäte, ktorá sa môže pridať k existujúcemu stavu pamäte.

- $C_t$ : Aktualizovaný stav pamäte po aplikácii vstupnej brány a brány zabudnutia.
- $h_t$ : Výstup siete, ktorý je smerovaný do ďalšej vrstvy alebo slúži ako výstup siete.
- $W_f, W_i, W_o, W_c$ : Váhové matice pre jednotlivé brány a kandidátnu hodnotu.
- $b_f, b_i, b_o, b_c$ : Bias vektory pre jednotlivé brány a kandidátnu hodnotu.
- $\sigma$ : Aktivačná sigmoidová funkcia.
- $\odot$ : Element-wise násobenie (Hadamardova operácia).
- $[h_{t-1}, x_t]$ : Konkatenácia vektorov  $h_{t-1}$  a  $x_t$ .

Spätná propagácia:

$$\begin{aligned} \frac{\partial C_{t+1}}{\partial h_t} &= \frac{\partial C_{t+1}}{\partial \tilde{C}_{t+1}} \frac{\partial \tilde{C}_{t+1}}{\partial h_t} + \frac{\partial C_{t+1}}{\partial f_{t+1}} \frac{\partial f_{t+1}}{\partial h_t} + \frac{\partial C_{t+1}}{\partial i_{t+1}} \frac{\partial i_{t+1}}{\partial h_t} \\ \frac{\partial C_{t+1}}{\partial C_t} &= \frac{\partial h_{t+1}}{\partial C_t} \frac{\partial C_{t+1}}{\partial h_{t+1}} \\ \frac{\partial h_{t+1}}{\partial h_t} &= \frac{\partial h_{t+1}}{\partial C_{t+1}} \frac{\partial C_{t+1}}{\partial h_t} + \frac{\partial h_{t+1}}{\partial o_{t+1}} \frac{\partial o_{t+1}}{\partial h_t} \end{aligned}$$

kde:

- $\frac{\partial C_{t+1}}{\partial h_t}$ : Derivácia chyby  $C_{t+1}$  vzhľadom k výstupu  $h_t$ .
- $\frac{\partial C_{t+1}}{\partial \tilde{C}_{t+1}}$ : Derivácia chyby  $C_{t+1}$  vzhľadom k výstupu z tanh vrstvy  $\tilde{C}_{t+1}$ .
- $\frac{\partial C_{t+1}}{\partial f_{t+1}}$ : Derivácia chyby  $C_{t+1}$  vzhľadom k výstupu zabudnutej brány  $f_{t+1}$ .
- $\frac{\partial f_{t+1}}{\partial h_t}$ : Derivácia výstupu zabudnutej brány  $f_{t+1}$  vzhľadom k výstupu  $h_t$ .
- $\frac{\partial i_{t+1}}{\partial h_t}$ : Derivácia výstupu vstupnej brány  $i_{t+1}$  vzhľadom k výstupu  $h_t$ .
- $\frac{\partial C_{t+1}}{\partial C_t}$ : Derivácia stavu  $C_t$  vzhľadom k stavu  $C_{t+1}$ .
- $\frac{\partial h_{t+1}}{\partial C_t}$ : Derivácia výstupu  $h_{t+1}$  vzhľadom k stavu  $C_t$ .
- $\frac{\partial C_{t+1}}{\partial C_t}$ : Derivácia stavu  $C_{t+1}$  vzhľadom k stavu  $C_t$ .
- $\frac{\partial h_{t+1}}{\partial o_{t+1}}$ : Derivácia výstupu  $h_{t+1}$  vzhľadom k výstupu výstupnej brány  $o_{t+1}$ .
- $\frac{\partial o_{t+1}}{\partial h_t}$ : Derivácia výstupu výstupnej brány  $o_{t+1}$  vzhľadom k výstupu  $h_t$ .



$$\begin{aligned}
\Pi_t &= \frac{\partial E_t}{\partial h_t} + \frac{\partial h_{t+1}}{\partial h_t} \Pi_{t+1} + \frac{\partial C_{t+1}}{\partial h_t} \mathcal{T}_{t+1} \\
\mathcal{T}_t &= \frac{\partial E_t}{\partial h_t} \frac{\partial E_t}{\partial C_t} + \frac{\partial h_{t+1}}{\partial C_t} \Pi_{t+1} + \frac{\partial C_{t+1}}{\partial C_t} \mathcal{T}_{t+1} \\
\beta_t^f &= \beta_{t+1}^f + \frac{\partial C_t}{\partial f_t} \frac{\partial f_t}{\partial W_t^f} \left( \frac{\partial h_t}{\partial C_t} \Pi_t + \mathcal{T}_t \right) \\
\beta_t^i &= \beta_{t+1}^i + \frac{\partial C_t}{\partial i_t} \frac{\partial i_t}{\partial W_t^i} \left( \frac{\partial h_t}{\partial C_t} \Pi_t + \mathcal{T}_t \right) \\
\beta_t^c &= \beta_{t+1}^c + \frac{\partial C_t}{\partial \tilde{C}_t} \frac{\partial \tilde{C}_t}{\partial W_t^c} \left( \frac{\partial h_t}{\partial C_t} \Pi_t + \mathcal{T}_t \right) \\
\beta_t^o &= \beta_{t+1}^o + \frac{\partial h_t}{\partial o_t} \frac{\partial o_t}{\partial W_t^o} (\Pi_t)
\end{aligned}$$

kde:

- $\Pi_t$ : Rekurzívny term pre spätnú propagáciu chyby vzhľadom k výstupu  $h_t$ .
- $\mathcal{T}_t$ : Rekurzívny term pre spätnú propagáciu chyby vzhľadom k stavu  $C_t$ .
- $\beta_t^f$ : Aktualizovaný parameter brány zabudnutia  $W_t^f$  pomocou spätných derivácií.
- $\beta_t^i$ : Aktualizovaný parameter vstupnej brány  $W_t^i$  pomocou spätných derivácií.
- $\beta_t^c$ : Aktualizovaný parameter vstupnej brány  $\tilde{C}_t$  pomocou spätných derivácií.
- $\beta_t^o$ : Aktualizovaný parameter výstupnej brány  $W_t^o$  pomocou spätných derivácií.

## 4.9 LSTM vs. RNN

Zhrnutie rozdielov [32]. Dlhodobá a krátkodobá pamäť predstavuje variant rekurentnej neurónovej siete s pridanými pamäťovými bunkami, čo umožňuje efektívne riešiť dlhodobé závislosti a eliminovať problém miznúceho gradientu, ktorý je bežným problémom pri štandardných RNN. LSTM sa vyznačuje komplexnou štruktúrou bunky s vstupnými, výstupnými a bránami zabudnutia, čo zlepšuje manipuláciu s informáciami v sekvenčných dátach. Na druhej strane, základný typ rekurentnej neurónovej siete disponuje jednoduchou štruktúrou bunky, ktorá je tvorená len skrytým stavom. Táto jednoduchosť však často vedie k problémom s dlhodobými závislosťami a miznúcim gradientom. RNN je vhodná pre jednoduché sekvenčné úlohy, ako je predpoveď časových radov, avšak jej schopnosť manipulovať s informáciami v dlhších postupnostiach je obmedzená. Celkovo, LSTM exceluje v úlohách, kde je kľúčová dlhodobá pamäť, ako napríklad pri preklade jazyka alebo analýze sentimentu.

Ak by sme mali rozdiely priblížiť na reálnom príklade, tak RNN je vhodná, ak chceme predpovedať predaj produktu v obchode na nasledujúci týždeň na základe dát z posledných niekoľkých týždňov. RNN by analyzovala denne zaznamenané predaje, ako aj relevantné faktory, ako sú aktuálne promo akcie, ceny alebo lokálne počasie. Model RNN by sa sústredil na vzorce, ktoré sú priamo zrejmé z nedávnych dát, a predpovedal by zmeny na základe týchto krátkodobých trendov v sektore FMCG. Na druhej strane, LSTM je lepšie vybavená na zachytávanie dlhodobých vzťahov a závislostí v dátach, čo je kľúčové v prípadoch, kde predaje ovplyvňujú dlhšie časové obdobia a skryté faktory, ako sú sezónne trendy

alebo efekty dlhotrvajúcich marketingových kampaní. Ak by sme mali predpovedať predaj napríklad zmrzliny, ktorý je silne sezónny a ovplyvnený dlhodobými faktormi ako počasie a prázdniny, LSTM by bola schopná zohľadniť sezónne vzory zaznamenané v dátach z viacerých predchádzajúcich rokov. Tento model by dokázal identifikovať a využiť dlhodobé vzťahy, ako napríklad zvýšenie predajov počas letných mesiacov alebo v období sviatkov, a poskytol by presnejšie predpovede na dlhšie časové obdobia.

## 4.10 Prehľad možných riešení problematiky pomocou umelej inteligencie

Tento text ponúka prehľad, analyzuje výhody a nevýhody rôznych techník a algoritmov umelej inteligencie, pričom kladie dôraz na ich uplatnenie v praxi.

V rámci umelej inteligencie (UI) existuje hierarchické usporiadanie [14], ktoré pomáha pochopiť rôzne úrovne komplexnosti a špecializácie techník, od najvšeobecnejších po najšpecifickejšie. Vrcholom tejto hierarchie je umelá inteligencia, ktorá zahŕňa všetky technológie a metódy napodobňujúce ľudskú inteligenciu. Pod UI sa nachádza strojové učenie (Machine Learning - ML), ktoré je špecifické súborom techník umožňujúcich počítačom učiť sa z dát bez explicitného programovania na vykonávanie špecifických úloh. Neurónové siete (Neural Networks - NN) tvoria podmnožinu ML a sú inšpirované štruktúrou a funkciou ľudského mozgu, umožňujúce modelovanie komplexných vzorcov a dynamík. Hlboké učenie (Deep Learning - DL) je ešte užšou podmnožinou neurónových sietí, ktorá využíva veľké neurónové siete s mnohými vrstvami na modelovanie extrémne zložitých vzorcov dát.

Hlboké učenie [25] je odvetvie strojového učenia, ktoré sa zameriava na vytváranie a tréningovanie veľmi komplexných modelov nazývaných hlboké neurónové siete. Tieto siete majú schopnosť automaticky extrahovať a transformovať vlastnosti z tréningových dát na rôznych úrovniach abstrakcie. Hlboké učenie využíva viacvrstvomé architektúry, kde informácie sú postupne prenášané cez viacero vrstiev neurónov. Medzi najpopulárnejšie typy hlbokých neurónových sietí patria: LSTM, RNN, CNN a GRU. Tento prístup je hlavným predmetom tejto práce a je bližšie popísaný v samostatných kapitolách.

### 4.10.1 Techniky UI

Techniky UI sa ďalej kategorizujú na základe typu učenia, ktoré zahŕňa [39]:

**(Učenie s učiteľom)** (Supervised learning): Metóda, pri ktorej model učí z dát, ktoré sú už označené, teda každá vzorka dát má priradený správny výstup alebo štítok. Cieľom je naučiť model tak, aby mohol predpovedať výstup pre nové, neoznačené dáta. Príklady algoritmov: Linear regression, logistic regression, decision trees, support vector machines (SVM).

**Učenie bez učiteľa** (Unsupervised learning): Využíva neoznačené dáta, teda dáta, ktoré nemajú preddefinované štítok. Cieľom je identifikovať skryté štruktúry alebo vzorce v dátových súboroch. Príklady algoritmov: K-means clustering, PCA (Principal Component Analysis).

**Učenie s posilňovaním** (Reinforcement learning): Agent sa učí správať v prostredí tak, aby maximalizoval kumulatívnu odmenu. Tento prístup sa zameriava na učenie sa správnych akcií prostredníctvom skúšania a omylov. Príklady algoritmov: Deep Q-Networks (DQN), Policy Gradients, SARSA.

**Učenie s učiteľom aj bez učiteľa - polousporiadané učenie** (Semi-supervised learning): Kombinuje označené a neoznačené dáta pri tréningu modelu. Táto metóda je zvlášť užitočná, keď je dostupné veľké množstvo neoznačených dát a len malé množstvo označených dát. Príklady algoritmov: Self-training, co-training, transductive SVM, graf-based methods.

#### 4.10.2 Algoritmy

V tejto časti sa zameriame na popis vybraných algoritmov umelej inteligencie a strojového učenia, ich potenciálne prínosy a negatíva pre použitie v predpovedi predajov v sektore rýchloobrátkového spotrebného tovaru.

**Lineárna regresia** (Linear Regression) [11] Je najjednoduchší algoritmus regresnej analýzy používaný na predpovedanie hodnoty závislej premennej (Y) na základe jednej alebo viacerých nezávislých premenných (X), ktorej výsledkom je spojitý výstup. Model sa snaží nájsť najlepšiu lineárnu rovnicu, ktorá opisuje vzťah medzi X a Y, čo sa matematicky vyjadruje ako  $Y = aX + b$ .

Prínosy: Jednoduchosť implementácie a vysoká interpretovateľnosť výsledkov. Umožňuje rýchlo identifikovať a kvantifikovať vplyv jednotlivých faktorov (cena, promo akcie) na predaje.

Negatíva: Obmedzená na lineárne vzťahy; nezachytáva komplexnejšie vzorce. Hlavnou nevýhodou je predpoklad lineárneho vzťahu medzi premennými, ktorý vo veľa prípadoch neodráža skutočnú dynamiku trhu FMCG, kde môžu byť vzťahy medzi premennými nelineárne alebo ovplyvnené externými faktormi.

**Rozhodovacie stromy** (Decision Trees) [33] Sú to modely, ktoré používajú stromovú štruktúru na rozhodovanie alebo predpovedanie výstupu. Každý vnútorný uzol stromu predstavuje test na atribúte, každá hrana k potomkovi reprezentuje výsledok testu, a každý listový uzol predstavuje výslednú predpoveď alebo triedu. Názov "rozhodovací strom" vyplýva z jeho schopnosti postupne deliť dátovú sadu na menšie časti až do dosiahnutia jednotlivých inštancií, ktoré sú potom klasifikované.

Prínosy: Rozhodovacie stromy sú účinné pri modelovaní nelineárnych vzťahov a interakcií medzi viacerými premennými. Sú intuitívne a ich výsledky sú ľahko interpretovateľné. Umožňuje identifikovať, ktoré faktory majú najväčší vplyv na predaje a ako rôzne segmenty produktov reagujú na rôzne stimuly.

Negatíva: Hlavným obmedzením je sklon k nadmernému učeniu (overfitting), kde model perfektne predpovedá tréningové dáta, ale má problémy s generalizáciou na nové, nevidené dáta. Môže byť citlivý na zmeny v dátach, čo vedie k nestabilným predpovediam pri meniacich sa trhových podmienkach.

**K-means zhlukovanie** (k-Means Clustering) [30] Je to algoritmus strojového učenia bez učiteľa. Cieľom je zoskupiť dáta tak, aby si body v rámci jedného zhluku boli čo najpodobnejšie, zatiaľ čo body v rôznych zhlukoch boli čo najviac odlišné. Zhlukom rozumieme skupinou bodov, ktoré sú si blízko na základe nejakej metriky.

Prínosy: Schopnosť odhaliť skryté vzorce a segmenty v dátach. Umožňuje segmentáciu trhu a zákazníkov na základe nákupného správania, čo pomáha v celení marketingu a optimalizácii zásob.

Negatíva: Nejedná sa priamo o prediktívny algoritmus a môže byť náročné určiť optimálny počet zhlukov. K-means tiež predpokladá, že zhluky sú konvexné a izometrické, čo nemusí vždy zodpovedať skutočným dátovým štruktúram. Neberie do úvahy časovú zložku, ktorá môže byť kľúčová pre analýzu trendov v predajoch.

**Polousporiadané učenie s využitím grafov na propagáciu štítkov** (Semi-Supervised Learning with Graph-Based Label Propagation) [10] Táto metóda kombinuje označené a neoznačené dáta pri tréovaní modelu. V grafovej reprezentácii dát sa štítky z označených bodov šíria do neoznačených bodov na základe podobnosti, čím sa zvyšuje množstvo informácií pre tréovanie modelu. Metóda funguje tak, že si predstavíme všetky naše dáta (každý riadok v našej tabuľke s údajmi) ako body v priestore. Medzi týmito bodmi potom nakreslíme čiary, ktoré ich spájajú na základe toho, ako sú od seba vzdialené. Na meranie tejto vzdialenosti môžeme použiť napríklad euklidovskú vzdialenosť, čo je spôsob, ako povedať, ako ďaleko sú body od seba vzdialené.

Prínosy: Schopnosť využiť veľké množstvo neoznačených dát. Môže zlepšiť presnosť modelov predpovedania predajov v situáciách, kde je označených dát málo.

Negatíva: Implementácia a výpočtová náročnosť môžu byť výzvou, najmä pri práci s veľkými dátovými súbormi. Vyžaduje tiež pevné pochopenie teórie grafov a metód propagácie štítkov.

**Podporné vektory** (Support Vector Machines - SVM) [13] Je to sada metód pre učenie s učiteľom, ktoré sa používajú na klasifikáciu, regresiu a detekciu odľahlých hodnôt. Využíva podmnožinu tréovacích bodov vo funkcii rozhodovania, ktoré nazývame podporné vektory, čím dosahuje aj pamäťovú efektívnosť.

Prínosy: Efektívnosť pri vysokodimenzionálnych dátach a robustnosť voči pretrénovaniu. Je možné ho využiť na klasifikáciu produktov podľa preferencií zákazníkov, čím umožňuje presnejšie cieľiť marketingové kampane. Ďalším príkladom je využitie na predikciu dopytu po nových produktoch na základe ich vlastností a vývoja predaja existujúcich produktov. Môže byť efektívnym nástrojom na identifikáciu odľahlých hodnôt v predajných dátach, čo môže pomôcť v riadení skladových zásob a optimalizácii dodávok.

Negatíva: Vyžaduje si starostlivý výber a nastavenie parametrov, ako je typ jadra a regularizačný parameter. Môže byť tiež náročný na výpočtové zdroje a čas na tréovanie, najmä pri veľkých dátových súboroch. Vyžaduje si veľké množstvo dát pre tréovanie a môže byť časovo náročný na optimalizáciu.

**Gated Recurrent Unit** (GRU) [24] Je to varianta rekurentných neurónových sietí (RNN), ktorá zjednodušuje štruktúru tradičných RNN. Má dva brány: resetovaciu a aktualizáciu, ktoré regulujú tok informácií a pomáhajú riešiť problém zmiznutia gradientu.

V podstate ide o dva vektory, ktoré rozhodujú o tom, aké informácie sa majú odovzdať na výstup. Je vhodný pre sekvenčné dáta, ako sú časové rady predajov, a dokáže zachytiť dlhodobé závislosti v dátach.

Prínosy: Efektívnejšie učenie a lepšia schopnosť zachytiť dlhodobé závislosti v dátach oproti tradičným RNN. Môže byť použitý na analýzu sekvenčných dát, ako sú časové rady predajov, a predpovedanie budúcich trendov.

Negatíva: Aj keď je efektívnejší než LSTM, môže byť v niektorých prípadoch menej presný. Vyžaduje veľké množstvo dát a čas na tréning pre dosiahnutie optimálnych výsledkov.

Pri predpovedi predaja v oblasti s rýchlo obrátkovým tovarom sa zdá práve LSTM dobrou voľbou v porovnaní s inými metódami strojového učenia. LSTM sa vyznačuje schopnosťou efektívne pracovať s dlhodobými závislosťami v sekvenčných dátach, čo je kľúčové pre správne zachytenie komplexných vzorov a trendov v predaji. Jeho štruktúra s vstupnými, výstupnými a bránami zabudnutia umožňuje manipuláciu s dlhodobou pamäťou, čo je dôležité pri identifikácii sezónnych trendov a iných dlhodobých faktorov ovplyvňujúcich predaj. LSTM taktiež rieši problém miznúceho gradientu, čo umožňuje efektívnejšie tréningovanie modelu v prítomnosti dlhých sekvencií dát.

## 4.11 Súčasný stav riešenia problematiky pomocou umelej inteligencie

Vo výskume "Demand Forecasting using Long Short-Term Memory Neural Networks"[29] bol skúmaný vplyv LSTM sietí na predpoveď dopytu v elektronickom obchode s potravinami. Tento tím zistil, že pokročilý viacrozmerový model LSTM poskytol lepšie predpovede pre potravinárske produkty v porovnaní s piatimi benchmarkovými modelmi a pre nápoje sa ukázal ako účinnejší než tri z referenčných modelov. Napriek tomu však lineárna regresia a modely náhodných lesov dosiahli miernu prevahu nad LSTM v určitých aspektoch. Tieto výsledky poukazujú na potenciál a obmedzenia LSTM v kontexte elektronického predaja potravín, pričom odporúčajú ďalšie štúdie s rozšírenými dátovými súbormi a dlhšími časovými radmi.

Vo výskumnej práci "A Comparative Study on Statistical and Machine Learning Forecasting Methods for an FMCG Company"[5] sa skúmali rozdiely medzi štatistickými metódami a metódami strojového učenia pri predpovedaní dopytu pre spoločnosti pôsobiace v odvetví rýchloobrátkového spotrebného tovaru (FMCG). Tento sektor generuje dennodenne stovky až tisíce transakcií, čo zvyšuje komplexnosť práce pre plánovačov dopytu, ktorí musia svoje predpovede vytvárať robustným a proaktívnym spôsobom. V práci sa preto venovala pozornosť využívaniu analýzy veľkých dát a predikčných metodológií na zistenie optimálnej metódy pre spracovanie údajov v tomto odvetví. Podľa analýz uvedených v dokumente štatistické metódy vo všeobecnosti predčili techniky strojového učenia, pričom modely SARIMA a ETS boli úspešnejšie ako KNN. Avšak, je dôležité podotknúť, že LSTM sa priblížila k SARIMA z hľadiska presnosti prispôsobenia modelu a bola hodnotená ako druhá najlepšia. Preto sa odporúčajú ďalšie experimenty s modelom LSTM, hlavne na dlhších časových horizontoch, kde všeobecne metódy strojového učenia sa javia byť efektívnejšie pri dlhších časových radoch.

## Kapitola 5

# Spracovanie dát

Dátová sada poskytuje komplexný pohľad na potravinárske produkty a faktory ovplyvňujúce ich predajnosť. Sada je usporiadaná do tabuľkovej formy (.csv), kde každý riadok reprezentuje unikátne meranie predaja jedného produktu v danom dni a stĺpce obsahujú rôzne charakteristiky týchto produktov a predajného miesta spolu s charakteristikou prostredia.

### 5.1 Popis dátovej sady

#### Popis stĺpcov:

- **Dátum (Date):** Tento atribút zaznamenáva presný dátum, na ktorý sa vzťahuje meranie a je kľúčový pre analýzu časových radov.
- **Produkt (Product):** Identifikuje konkrétny potravinársky výrobok, ktorého predaj je analyzovaný. Každý produkt je unikátny svojou špecifikáciou a kategorizáciou.
- **Typ podľa doby použiteľnosti (Type according to shelf life):** Rozlišuje produkty na základe ich trvanlivosti, čo môže mať priamy vplyv na frekvenciu a objem nákupov.
- **Typ (Type):** Klasifikuje produkty do rôznych skupín, ktoré môžu indikovať rôzne spotrebiteľské vzorce a preferencie.
- **Kus/kg (Piece/kg):** Hovorí o objeme predaja, buď v počte kusov alebo hmotnosti.
- **Hustota konkurenčných obchodov (Density of competing stores):** Odráža množstvo alternatívnych nákupných možností v oblasti.
- **Bonita štvrte (Good standing of the neighborhood):** Hodnotí socioekonomický status štvrte.
- **Deň roka (Day of the year):** Poskytuje kontext o sezónnych vplyvoch alebo špecifických obdobiach. 1.1. s označením 1, 31.12. s označením 366 (vrátane priestupného roku).
- **Víkend (Weekend):** Indikuje, či dátum patrí do víkendu.

- **Dážď a Sneh (Rain and Snow):** Indikátory označujúce, či v daný deň pršalo alebo snežilo.
- **Teplota (Temperature):** Priemerná nameraná teplota v daný deň.
- **Školské prázdniny a Dovolenka (School holiday, Holiday):** Tieto premenné idnikujú, či v daný dátum bol sviatok alebo školské prázdniny.
- **Zlava (Discount):** Zaznamenáva, či bol produkt ponúkaný so zlavou.
- **Trvanlivosť (Shelf life):** Doba, po ktorú je produkt bezpečne konzumovať.
- **Cena (Price):** Predajná cena produktu.
- **Predaj (Sales):** Tento údaj odráža skutočný objem predaja produktu v danom dni.
- **Predaj-1 až Predaj-14 (Sales-1 – Sales-14):** Zahrnutie predajov za predchádzajúcich 14 dní.
- **Priemer (Average):** Priemerná hodnota predaja za určité obdobie (14 dní).

Tieto atribúty umožňujú detailnú analýzu a vytvorenie prediktívneho modelu, ktorý dokáže efektívne predpovedať budúce predaje na základe historických dát a rôznych vstupných faktorov.

V dátovej sade je kľúčové, že všetky dáta sú kvantifikované do číselných hodnôt, aby boli spracovateľné pre matematické a štatistické modely, ktoré sú využité pri predikcii predaja. Tento prístup umožňuje použiť algoritmy strojového učenia, ako sú neurónové siete LSTM, ktoré vyžadujú numericky expresívne dáta. Produkty, obchodné miesta a kategórie: Tieto prvky sú analyzované s dôrazom na ich predajný potenciál a vplyv na spotrebiteľské správanie. Každá položka je podrobená odbornému hodnoteniu na základe historických predajných dát a priradená do určitej kategórie alebo triedy, čo reflektuje jej trhovú pozíciu a preferenciu spotrebiteľa.

#### **Príklady kvantifikácie:**


- **Sneh/Dážď:** Tento binárny atribút, s hodnotami 1 alebo 0, indikuje, či v danom dni pršalo alebo snežilo.
- **Deň v roku:** Reprezentovaný číslom od 1 do 366 (pozn. priestupný rok).
- **Obdobie sviatkov:** Táto premenná je binárna, s hodnotami 0 pre 'nie je sviatok' a 1 pre 'je sviatok'.
- **Trvanlivosť:** Udáva počet dní, počas ktorých je možné produkt bezpečne konzumovať. Číslovaná od 1 do x, kde x je maximálna trvanlivosť niektorého z produktov.
- **Bonita štvrte:** Hodnotí sa na škále od 0 do 4, kde každá hodnota odráža socioekonomický status štvrte. Vyššie čísla môžu značiť štvrte s vyššou kúpnu silou a lepšou infraštruktúrou.

## 5.2 Spracovanie dátovej sady

Táto časť je zameraná na spracovanie a prípravu dátovej sady pred vstupom do neurónovej siete.

**Rozdelenie na vlastnosti (features) a ciele (targets):** Vlastnosti (Features): Sú nezávislé premenné z dátovej sady, ktoré poskytujú informácie pre model na predpovedanie cieľovej hodnoty. V tomto prípade by to mohli byť časové údaje (napr. deň v roku), počasie (dážď/sneh), teplota, prítomnosť sviatkov, špeciálne obdobia (školské prázdniny, dovolenka) a marketingové faktory (zľavy). Ciele (Targets): Je to závislá premenná, ktorá je výsledkom, ktorý sa model snaží predpovedať. V kontexte predaja potravinárskeho tovaru by cieľom bol 'Predaj', teda množstvo predaných jednotiek produktu.

**Normalizácia dát - škálovanie do rozsahu 0-1 (Scaling):** Normalizácia údajov je kritickým krokom, ktorý pomáha zabezpečiť, že jednotlivé vlastnosti prispievajú rovnomerne k predikčnej schopnosti modelu. Bez tohto kroku by mohli vlastnosti s vyššími absolútnymi hodnotami nadmieru ovplyvniť model. Použitie MinMaxScaler v Pythone je štandardná metóda normalizácie, ktorá pretransformuje každú vlastnosť individuálne tak, že jej minimálna hodnota bude 0 a maximálna hodnota bude 1. Tento krok je zvlášť dôležitý pre modely LSTM, keďže sú citlivé na rôzne škály vstupných dát. Vytvorenie sekvencií údajov (Creating data sequences): LSTM siete sú určené na prácu s časovými radmi a z toho vyplýva, že dôležitým aspektom je sekvenčná povaha vstupných údajov. Pri tréovaní LSTM na predpovedanie predaja potravinárskych produktov chceme modelu poskytnúť kontext v podobe dát z predchádzajúcich dní. Sekvencie dát sú vytvorené tak, že každá vstupná vzorka je okno, ktoré obsahuje informácie o predaji a iných vlastnostiach za určité časové obdobie (napríklad 14 dní). Tento prístup umožňuje modelu zachytiť vzory a závislosti, ktoré sa vyskytujú v čase.



Obr. 5.1: Normalizácia dát [15]



### 5.3 Reálne dáta a ich kategorizácia

**Obchodné miesta využité v dátovej sade (miesta kde boli zbierané dáta):**

Aupark - Einsteinova 18, 851 01 Petržalka, Slovensko

Gercenova - Gercenova 4, 851 01 Petržalka, Slovensko

Slnčnice - Zuzany Chalupovej 5, 851 07 Bratislava, Slovensko

Šustekova - 6, Šustekova 3621/4, 851 04 Petržalka, Slovensko

Obchodné miesto	Bonita štvrte	Hustota konkurenčných obchodov
Aupark	3	3
Gercenova	1	2
Slnčnice	2	3
Šustekova	1	1

Tabuľka 5.1: Obchodné miesta

Bonita štvrte	Hustota konkurenčných obchodov
0 - žiadna	0 - žiadna
1 - slabá	1 - slabá
2 - mierna	2 - mierna
3 - silná	3 - silná
4 - veľmi silná	4 - veľmi silná

Tabuľka 5.2: Ohodnotenie obchodných miest

Nasledujúce tabuľky zobrazujú priradenie ID k použitým produktom v súbore údajov, ich kategorizáciu a ohodnotenie.

Kategória	Hodnota
varené mäso, klobásky	1
chladené mäso	2
pečivo	3
jogurty	4
konzervy	5
syry	6
iné	7

Tabuľka 5.3: Hodnoty kategórií

Produkt	ID
Sunka slovenska- 0141	1
Balene parky lahodkove- 0220	2
Chlieb Dvojrsko kvaskovy 500g- 0704	3
Rozok s pšenickým kvasom 50g- 0706	4
Tvaroh z Horehronia 250g- 0442	5
Sunka morcacia FIT Masovinky- 30136	6
Hovadzie stehno BP- 30200	7
Mrkvace 260g- 0807	8
Roztek makovy plneny 250g- 0777	9
Ginger Shot Citron Med 200ml- 0944	10
Krem SLOWTELLA z lieskovcov a kakaa 250g- 1948	11
Pasteta kacacia 160g SO- 30173	12
Jogurt smot. biely 150g KUKKONIA- 0402	13
Kuracie prsia Kralov Brod- 0286	14
Klobasa Jablonicka- 30130	15

Tabuľka 5.4: ID produktov

ID	Trvanlivosť	Kategória	PC s DPH	Cena Akcia	kus/kg	Typ trv.	Typ
5	17	syry kravské	1,99 €		0	1	6
3	1	chlieb	3,26 €		0	0	3
4	1	rožky a žemle	0,36 €		0	0	3
9	7	trvanlivé pečivo	4,89 €	4,07 €	0	1	3
8	7	trvanlivé pečivo	5,7 €	4,69 €	0	1	3
10	365	šťavy a nektáre	7,79 €	6,59 €	0	2	7
11	365	orechové maslá	13,69 €	12,98 €	0	2	7
15	21	klobásy a salámy	19,90 €	17,20 €	1	1	1
6	21	varene mäso	29,90 €	18,71 €	1	1	1
12	90	konzervy	4,60 €	3,9 €	0	2	5
7	7	chladené mäso	30,43 €		1	1	2

Tabuľka 5.5: Kategorizácia produktov

# Kapitola 6

## Implementácia

### 6.1 Python

Python [35] sa stal vedúcim programovacím jazykom v oblasti strojového učenia vďaka niekoľkým významným vlastnostiam. Jednou z kľúčových je jeho ľahko čitateľná syntax, ktorá zjednodušuje písanie a pochopenie kódu. Okrem toho disponuje rozsiahlymi knižnicami, ktoré sú k dispozícii pre vývojárov, čím zjednodušujú implementáciu komplexných algoritmov strojového učenia. Python tiež vyniká svojou schopnosťou bežať na rôznych platformách, čo znamená, že kód napísaný v tomto jazyku môže byť použitý na rôznych operačných systémoch. Jeho všestrannosť a prispôsobivosť umožňujú vývojárom adresovať široké spektrum zložitých problémov strojového učenia. Medzi tieto problémy patria napríklad rozpoznávanie obrazu, spracovanie reči, prediktívna analýza a dokonca aj vývoj systémov pre autonómne vozidlá.

### Knižnice a moduly

**NumPy** (Numerical Python) je základná knižnica pre vedecké výpočty v jazyku Python. Poskytuje vysoko výkonné nástroje na prácu s veľkými maticami a poliami dát, čo je kľúčové pre rôzne oblasti vedeckých výskumov, štatistiky, a najmä pre implementáciu algoritmov strojového učenia. NumPy je slobodný softvér uvoľnený pod licenciou BSD-new a napísaný čiastočne priamo v Pythone a čiastočne v C.

**TensorFlow** je bezplatná softvérová knižnica s otvoreným zdrojovým kódom pre strojové učenie a umelú inteligenciu. Dá sa použiť naprieč celým radom úloh, ale zameriava sa najmä na tréning a odvodenie hlbokých neurónových sietí. Poskytuje vysokoúrovňové API používané na jednoduché vytváranie a tréningovanie modelov

**Keras** [1] je vysokoúrovňové API, ktoré vyvinula spoločnosť Google s cieľom uľahčiť implementáciu neurónových sietí. Táto knižnica je napísaná v jazyku Python a vyniká v tom, že zjednodušuje proces vytvárania a tréningovania modelov. Jeho relatívne jednoduchý a zrozumiteľný prístup z neho robí vhodný nástroj pre začiatočníkov v oblasti strojového učenia. Keras poskytuje pythonové rozhranie s vysokou úrovňou abstrakcie, čo umožňuje užívateľom efektívne pracovať s neurónovými sieťami bez potreby detailného pochopenia podrobnej matematiky a implementačných detailov. Jedným zo silných stránok Kerasu je

jeho modularita a flexibilita, ktoré umožňujú vývojárom výber z viacerých backendových výpočtových rámcoch podľa ich potrieb.

**Pandas** je softvérová knižnica napísaná pre programovací jazyk Python, určená na manipuláciu a analýzu dát. Konkrétne ponúka štruktúry dát a operácie na manipuláciu s číselnými tabuľkami a časovými radmi. Hlavnou dátovou štruktúrou v Pandas je DataFrame, ktorý umožňuje ukladanie a manipuláciu s tabuľkovými dátami. Je to bezplatný softvér uvoľnený pod licenciou BSD.

**Scikit-learn (sklearn)** je jedna z najpopulárnejších knižníc pre strojové učenie v Pythone. Poskytuje jednoduché a efektívne nástroje pre analýzu dát a modelovanie dát. **MinMaxScaler** je transformácia z scikit-learn, ktorá škáluje a premení vlastnosti tak, že ich umiestni do daného rozsahu, často medzi mínus jednou a jednou.

**Jupyter Notebook** je webová aplikácia s otvoreným zdrojom, ktorá poskytuje interaktívne prostredie pre vytváranie a zdieľanie dokumentov obsahujúcich živý kód, rovnice, vizualizácie a textový popis. Tento nástroj je populárny v oblasti dátového vedy, výskumu a vzdelávania. Jupyter Notebook umožňuje používateľom písať kód v rôznych programovacích jazykoch, vrátane Pythonu, R, Julia a ďalších. Kód sa vykonáva v bunkách, čo znamená, že môžete spúšťať jednotlivé časti kódu nezávisle.

**Matplotlib** je knižnica pre vytváranie statických, animovaných a interaktívnych vizualizácií v Pythone. Poskytuje objektovo orientované API pre vloženie grafov do aplikácií používajúcich všeobecné GUI nástroje, ako sú Tkinter, wxPython, Qt alebo GTK. Je široko používaná pre vedecké grafy, má podporu pre rôzne druhy grafov a vizualizácií.

## 6.2 Implementácia v Pythone

Vo fáze spracovania údajov sa aplikuje škálovacia transformácia na funkcie aj ciele, aby sa zabezpečilo, že hodnoty budú normalizované, čím sa zvýši výkon modelov strojového učenia. Nižšie je uvedený kód Pythonu použitý v tomto procese:

```
1 feature_scaler = MinMaxScaler(feature_range=(0, 1))
2 target_scaler = MinMaxScaler(feature_range=(0, 1))
3 feature_scaler.fit_transform(features)
4 target_scaler.fit_transform(targets)
5
6 def create_sequences(self, features, targets, seq_length):
7     xs, ys = [], []
8     for i in range(len(features) - seq_length):
9         x = features[i : (i + seq_length)]
10        y = targets[i + seq_length]
11        xs.append(x)
12        ys.append(y)
13    return np.array(xs), np.array(ys)
```

Samotné využitie modelu v predikcii zahŕňa niekoľko etáp:

**Inicializácia modelu (Init):** Inicializácia modelu v Keras začína definovaním štruktúry modelu, ktorá zahŕňa určenie počtu vrstiev, počet jednotiek v každej LSTM vrstve a pridanie vrstiev, ako sú „Dropout“ pre zabránenie „overfittingu“, a „Dense“ pre výstupné predikcie. Tiež aktivačné funkcie, ako napríklad 'relu' alebo 'tanh'

**Trénovanie modelu (Train):** Trénovanie začína dodaním dátovej sady na trénovanie do modelu. Tento proces sa uskutočňuje cez metódu „fit“, kde sa definuje vstupné a cieľové dáta, počet epoch (iterácií cez dátovú sadu), veľkosť „batchu“ (počet vzoriek, ktoré sú spracované pred aktualizáciou modelu), a voliteľne validačné dáta pre sledovanie výkonu modelu po každej epoche. Počas tréningu sa váhy sieťovej jednotky aktualizujú tak, aby minimalizovali chybu predpovede.

**Vyhodnotenie modelu (Evaluation):** Po tréningu je potrebné vyhodnotiť model na testovacej sade dát, ktoré model ešte nevidel. Vyhodnotenie poskytuje metriky, ako sú strata (loss) a validačná strata (validation loss), ktoré nám umožňujú posúdiť, ako dobre model predpovedá na nevidených dátach. Chybu predpovede môžeme vyhodnotiť ako Mean Squared Error (MSE) alebo Root Mean Squared Error (RMSE).

**Predpovedanie pomocou modelu (Prediction):** Akonáhle je model adekvátne vyhodnotený a výsledky validácie a straty sú prijateľné, môže sa model použiť na predpovedanie výsledkov pre nové dáta. To sa uskutočňuje prostredníctvom metódy „predict“, kde sa vložia nové vstupné dáta a model vráti predpovede, ktoré reflektujú očakávaný predaj v závislosti od poskytnutých vstupov.

**Úprava Modelu (Fine-tuning):** Na základe výsledkov vyhodnotenia sa môže model upravovať. To môže zahŕňať úpravy architektúry modelu, ako je pridanie alebo odstránenie vrstiev, menenie počtu jednotiek v LSTM vrstvách, upravenie parametrov (ako je rýchlosť učenia, veľkosť batchu a pod.) alebo upravenie metód predspracovania dát. Cieľom je zlepšiť presnosť modelu na testovacej sade a zabezpečiť, aby model generalizoval dobre na nové dáta.

```
1 # Inicializacia modelu
2 model.add(LSTM(units, activation, input_shape, return_sequences, dropout,
3               recurrent_dropout))
4 model.add(Dense(dense))
5 model.compile(optimizer, loss)
6 # Trenovanie modelu
7 early_stopping = EarlyStopping(monitor, patience, mode)
8 model.fit(X_train, y_train, epochs, batch_size, validation_data, callbacks=[
9           early_stopping], shuffle)
10 # Ohodnotenie
11 model.evaluate(X_test, y_test)
12
13 # Predikcia
14 model.predict(X)
```

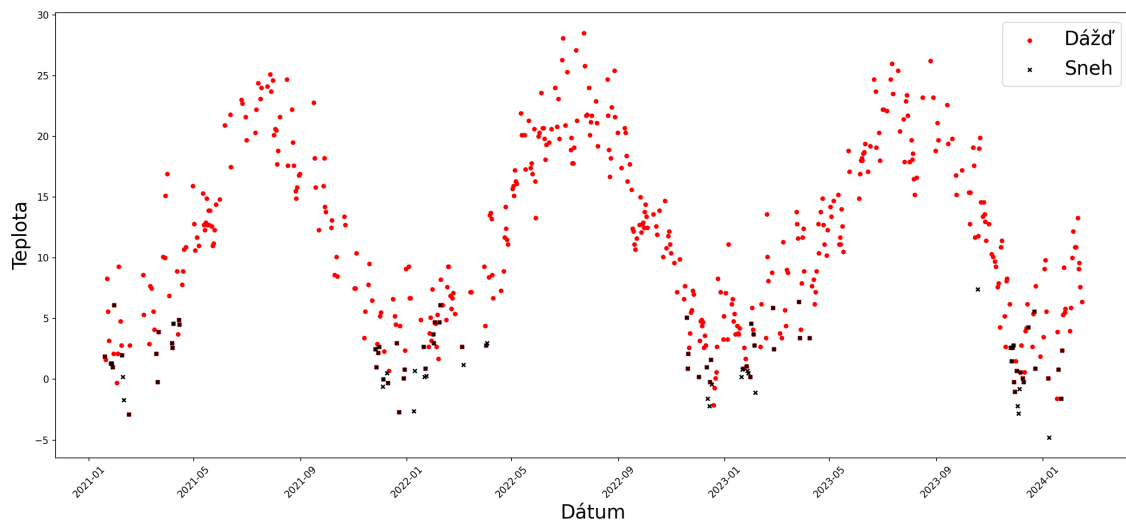
# Kapitola 7

## Praktická časť

V praktickej časti práce dochádza k aplikácii teoretických poznatkov na reálne údaje, čím sa preveruje funkčnosť a efektivita LSTM modelu. Táto časť sa podrobne zaoberá tromi hlavnými experimentmi.

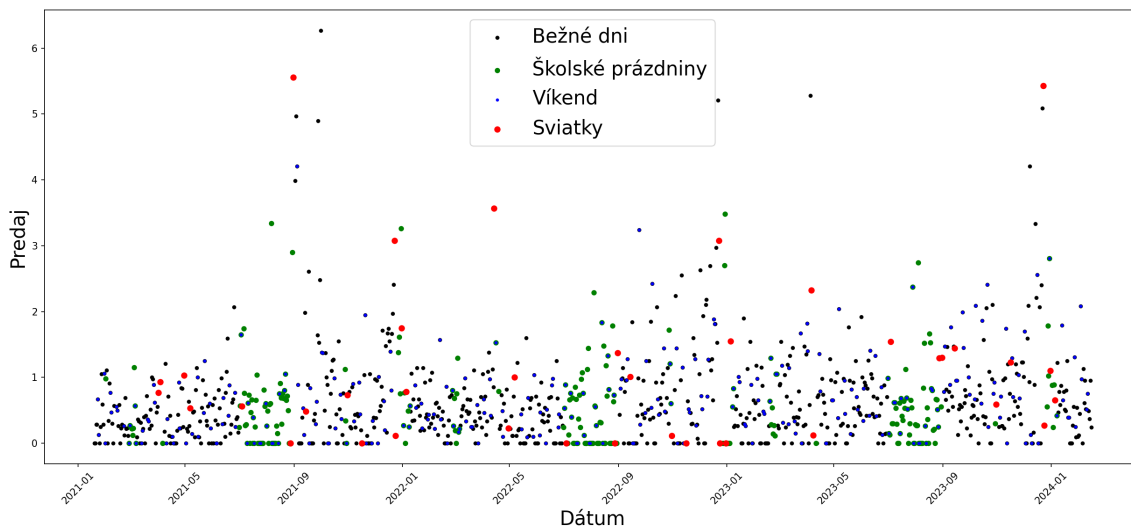
### 7.1 Grafické zobrazenie vstupných faktorov

Obr. 7.1: Dážď, Sneh, Teplota - Tento graf ilustruje meteorologické podmienky, kde je zobrazená korelácia medzi teplotou a dňami kedy snežilo alebo pršalo. Dážď, sneh a teplota sú základné klimatické premenné, ktoré majú vplyv na predaj tovaru.




Obr. 7.1: Dážď, Sneh, Teplota

Obr. 7.2: Víkendy, Sviatky, Školské prázdniny - Tento graf sa zameriava na časové faktory, ako sú víkendy, sviatky a školské prázdniny voči celkovým predajom produktu Klobása Jablonická. Tieto dni môžu výrazne ovplyvniť spotrebiteľské správanie a ďalšie sociálno-ekonomické aktivity. Pochopenie ich vplyvu je dôležité pre tvorenie predikcií, ktoré zohľadňujú sezónne a pravidelné výkyvy v správaní ľudí voči trhu.




Obr. 7.2: Víkendy, Sviatky, Školské prázdniny

Obr. 7.3 a 7.4: Predaj, Priemer, Akcia - Tieto grafy prezentujú ekonomické ukazovatele spojené s predajom. Analýza ukazuje ako špeciálne ponuky (akcie) a 14 dňový priemer predaja ovplyvňujú obchodnú dynamiku. Obr. 7.3 ukazuje predaj sladkého pečiva Mrkváče a obr. 7.4 mäsového výrobku Klobása Jablonická.



Obr. 7.3: Predaj, Priemer, Akcia (Mrkváče - 8)



Obr. 7.4: Predaj, Priemer, Akcia (Klobása Jablonická - 15)

## 7.2 Experiment č.1

Prvý experiment sa sústreďuje na hĺbkovú analýzu predajov jedného konkrétneho produktu počas trojročného obdobia vo všetkých predajniach. Každý dátový záznam v tejto sade obsahuje nielen informácie o predajoch na daný deň, ale tiež agregované údaje z predchádzajúcich 14 dní, vrátane ich priemeru. Tento prístup poskytuje modelu širší kontext a umožňuje lepšie pochopenie krátkodobých fluktuácií a dlhodobých trendov v predajoch. Cieľom tohto experimentu je overiť, či LSTM model dokáže efektívne využiť informácie z krátkodobého časového rámca na predpovedanie predajov, a zároveň zistiť, ako dobre dokáže model identifikovať a zohľadniť dlhodobé sezónne vzory a zmeny.

Na vyhodnotenie predikčnej sily modelu LSTM je tu porovnanie skutočných údajov o predaji s predpoveďami modelu. Nasledujúce časti sumarizujú skutočné čísla predajov a zodpovedajúce prognózy za obdobie 1.1.2024 - 29.2.2024.

### 7.2.1 Testovaný produkt Mrkváče (ID: 8)

**Celkový predaj:** Model predpovedal celkové predaje 3863 kusov produktu oproti reálnym 3938, čo robí rozdiel 75 kusov za obdobie január a február 2024.

**Priemerný predaj za deň:** Model predpovedal priemerný denný predaj 67,90, čo je o niečo viac ako skutočný priemer 66,60. To naznačuje tesnú zhodu v schopnosti modelu predpovedať denné objemy predaja, hoci mierne nadhodnocuje priemer.

**Maximálny predaj za jeden deň:** Predpokladaný maximálny predajný deň bol 106, čím prekonal skutočné maximum 92,59. Toto nadhodnotenie by mohlo naznačovať model zachytávajúci potenciálne vrcholy predaja za určitých podmienok, ktoré neboli pozorované počas skutočného obdobia predaja.



**Minimálny predaj v jeden deň:** Naopak, predpokladaný minimálny predajný deň bol 20, čo je menej ako skutočné minimum 23,81. Toto podcenenie naznačuje, že hoci je model vo všeobecnosti účinný, nemusí plne zohľadňovať faktory, ktoré bránia poklesu predaja pod určitú hranicu.

$$\text{Percentuálna chyba pre celkový predaj} = \left( \frac{3863 - 3938}{3938} \right) \times 100 \approx -1.90\%$$


$$\text{Percentuálna chyba pre priemer} = \left( \frac{66.60 - 67.89}{67.89} \right) \times 100 \approx -1.90\%$$

$$\text{Percentuálna chyba pre maximálny predaj} = \left( \frac{93 - 106}{106} \right) \times 100 \approx -12.26\%$$


$$\text{Percentuálna chyba pre minimálny predaj} = \left( \frac{24 - 20}{20} \right) \times 100 \approx 20.00\%$$

Metrika	Skutočný predaj	Predikovaný predaj	Percentuálna chyba
Celkový predaj	3938	3863	-1.90%
Priemerný predaj	67.89	66.60	-1.90%
Maximálny predaj	106	93	-12.26%
Minimálny predaj	20	24	20.00%

Tabuľka 7.1: Porovnanie skutočného a predpokladaného predaja s percentuálnymi chybami (Mrkváče)



Obr. 7.5: Strata a Validačná strata (Mrkváče - 8)



Obr. 7.6: Predikcie predajov (Mrkváče - 8)

### 7.2.2 Testovaný produkt Klobásy (ID: 15)

**Celkový predaj:** Model predpovedal celkové predaje 39.46 kusov produktu oproti reálnym 33.74, čo robí rozdiel 5.72 kusov za obdobie január a február 2024.

**Priemerný predaj za deň:** Model predpovedal priemerný denný predaj 0.68, čo je viac ako skutočný priemer 0.58. Toto nadhodnotenie naznačuje, že model predpovedá vyššie denné predaje než sú skutočné.

**Maximálny predaj za jeden deň:** Predpokladaný maximálny predajný deň bol 1.27, čo je výrazne menej ako skutočné maximum 2.08. Tento výsledok môže naznačovať, že reálne predaje dosiahly niektorý deň čísla mimo noriem.

**Minimálny predaj za jeden deň:** Model predpovedal minimálny predaj 0.018, kým skutočný minimálny predaj bol 0. Toto nadhodnotenie ukazuje na limitácie modelu v predpovedi nulových predajov.

Percentuálna chyba pre celkový predaj = 16.93%


Percentuálna chyba pre priemer = 16.95%

Percentuálna chyba pre maximálny predaj = -38.82%


Percentuálna chyba pre minimálny predaj =  $N/A$

Metrika	Skutočný predaj	Predikovaný predaj	Percentuálna chyba
Celkový predaj	33.74	39.46	16.93%
Priemerný predaj	0.58	0.68	16.95%
Maximálny predaj	2.08	1.27	-38.82%
Minimálny predaj	0.0	0.018	N/A

Tabuľka 7.2: Porovnanie skutočného a predpokladaného predaja s percentuálnymi chybami (Klobásy)



Obr. 7.7: Strata a Validačná strata (Klobása Jablonicka - 15)



Obr. 7.8: Predikcie predajov (Klobása Jablonicka - 15)

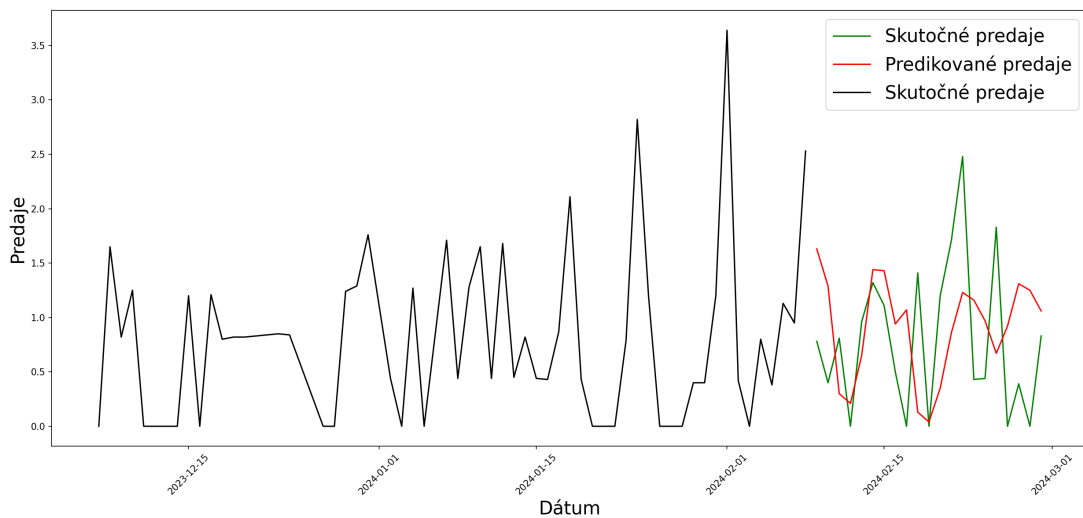
## 7.3 Experiment č.2

Cieľom tohto experimentu je rozšíriť metodológiu použitú v prvom experimente pre predpovede predaja, tentoraz s iným prístupom k dátam a modelovaniu. Zatiaľ čo prvý experiment predpovedal mesačné predaje produktu využitím 14-dňových dátových sekvencií, tento experiment sa zameriava na predpovedanie predajov produktu za obdobie, ktoré je priamo ovplyvnené trvanlivosťou produktu a frekvenciou jeho objednávaní. Napríklad pre tvaroh so 17 dňovou trvanlivosťou je využitá 17-dňová dátová sekvencia a sú predpovedané predaje na nasledujúcich 17 dní. Na tréningovanie sú využité dáta predajov za rok 2023.


Metrika	Skutočný predaj	Predikovaný predaj	Chyba[%]
Balene parky lahodkove (2)	16.6	18.9	13.8%
Roztek makovy plneny 250g (9)	52	50	-3.84%
Tvaroh z Horehronia 250g (5)	52	63	21.1%

Tabuľka 7.3: Porovnanie skutočného a predpokladaného predaja s percentuálnymi chybami


V rámci experimentu s predpovedaním predaja produktov bol zaznamenaný rozsah chýb od 3% do 21%. Tieto odchýlky v presnosti modelu môžu byť spojené s niekoľkými faktormi, medzi ktoré patrí aj obmedzený objem dát, s ktorými model pracuje. Malý dátový set zvyšuje pravdepodobnosť, že výsledky predpovedí budú ovplyvnené lokálnymi extrémami, ktoré nemusia presne odrážať širšie trhové trendy.



Obr. 7.9: Predikcie predajov (Balene parky lahodkove - 2)



Obr. 7.10: Predikcie predajov (Roztek makovy plneny 250g - 9)




Obr. 7.11: Predikcie predajov (Tvaroh z Horehronia 250g - 5)

## 7.4 Experiment č.3

Tretí experiment zahŕňa dátovú sadu s dennými záznamami predajov 15 rozličných produktov v 4 rôznych obchodných miestach, čo predstavuje pestrosť a komplexnosť reálneho obchodného prostredia. Tieto dáta sú pozorované a analyzované počas jedného roka. Produkty sú v tejto sade anonymizované a reprezentované unikátnymi číselnými identifikátormi, aby sa zabezpečila konzistencia a možnosť automatizovaného spracovania. Obchodné miesta sú kategorizované podľa geografického umiestnenia a charakteristík okolia, čo umožňuje skúmať vplyv lokality na predajnosť produktov.

V rámci tohto experimentu sa LSTM model trénuje na rozpoznanie vzorcov a trendov, ktoré sú špecifické pre jednotlivé produkty a obchodné miesta, pričom zohľadňuje aj vonkajšie vplyvy ako počasie či sviatky. Cieľom je presne predpovedať budúci predaj pre každý produkt na základe historických dát, čím sa testuje schopnosť modelu adaptovať sa na rozmanité podmienky.




Obr. 7.12: Strata a Validačná strata (Spolu)

Predikcie pre testované produkty sú za obdobie 1.2.2024 - 29.2.2024.

#### 7.4.1 Testovaný produkt Šunka slovenska (ID: 1)

Metrika	Skutočný predaj	Predikovaný predaj	Chyba[%]
Celkový predaj - Aupark	59.89	52.86	-11.74%
Priemerný predaj - Aupark	2.06	1.82	-11.65%
Maximálny predaj - Aupark	3.75	1.95	-48%
Minimálny predaj - Aupark	0.65	1.66	155.38%
Celkový predaj - Šustekova	10.55	7.99	-24.22%
Priemerný predaj - Šustekova	0.42	0.32	-23.81%
Maximálny predaj - Šustekova	1.34	0.41	-69.40%
Minimálny predaj - Šustekova	0	0.18	N/A

Tabuľka 7.4: Porovnanie skutočného a predpokladaného predaja s percentuálnymi chybami (Šunka slovenská)

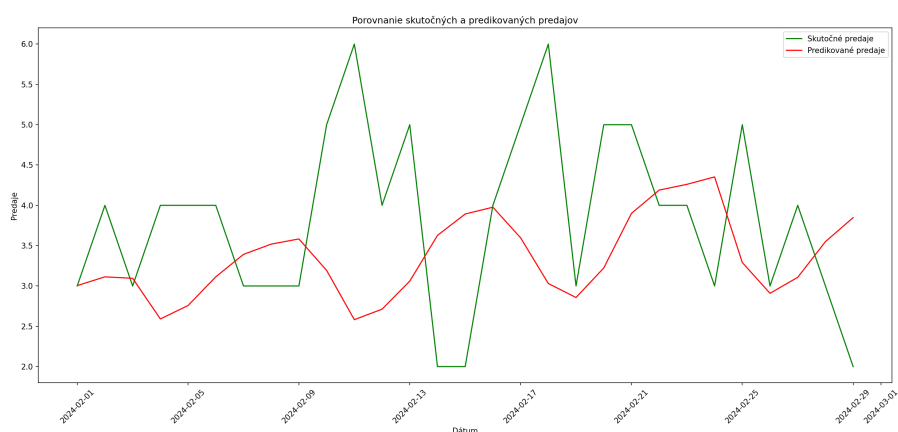


Obr. 7.13: Predikcie predajov (Šunka slovenská - 1) Aupark

#### 7.4.2 Testovaný produkt Chlieb Dvojrnrko kvaskovy (ID: 3)

Metrika	Skutočný predaj	Predikovaný predaj	Chyba[%]
Celkový predaj - Aupark	111	97	-12.61%
Priemerný predaj - Aupark	3.82	3.34	-12.57%
Maximálny predaj - Aupark	6	4	-33.33%
Minimálny predaj - Aupark	2	3	50%
Celkový predaj - Slnčnice	77	66	-14.29%
Priemerný predaj - Slnčnice	2.65	2.28	-13.96%
Maximálny predaj - Slnčnice	5	3	-40.00%
Minimálny predaj - Slnčnice	0	2	N/A

Tabuľka 7.5: Porovnanie skutočného a predpokladaného predaja s percentuálnymi chybami (Chlieb Dvojrnrko kvaskovy)



Obr. 7.14: Predikcie predajov (Chlieb dvojrnrko 3) Aupark

# Kapitola 8

## Vyhodnotenie výsledkov

### 8.1 Vyhodnotenie výsledkov prognózy pre experiment č.1

V tejto časti je hodnotenie modelu počas dvojtýždňového intervalu objednávania od 16. februára do 29. februára 2024. Predpovede modelu a skutočné údaje o predaji za toto obdobie sú uvedené nižšie, po ktorých nasleduje kvantitatívne vyhodnotenie výkonu modelu.

#### 8.1.1 Predikované a aktuálne dáta o predaji

Mrkváče(ID: 8) a Klobása Jablonická(ID: 15)

P - Predikované predaje R - Reálne predaje

Deň	P - Mrkváče	R - Mrkváče	P - Klobása	R - Klobása
16.2.2024	93	84	0.69	0.82
17.2.2024	62	59	0.67	1.22
18.2.2024	25	42	0.43	0.46
19.2.2024	49	70	0.32	0.58
20.2.2024	79	80	0.29	0.45
21.2.2024	77	67	0.34	0.00
22.2.2024	89	85	0.56	0.28
23.2.2024	92	84	0.76	0.63
24.2.2024	62	66	0.67	0.85
25.2.2024	28	24	0.49	0.00
26.2.2024	53	46	0.36	0.46
27.2.2024	87	73	0.37	0.58
28.2.2024	78	70	0.42	0.00
29.2.2024	82	99	0.52	0.11
Spolu	961	949	6.96	6.44

Tabuľka 8.1: Porovnanie predpokladaného a skutočného predaja Mrkváčov za obdobie dvoch týždňov

#### 8.1.2 Kvantitatívne hodnotenie

Na kvantitatívne vyhodnotenie výkonnosti modelu je vypočítaný celkový rozdiel medzi predpokladaným a skutočným predajom:



$$\text{Celkový absolútny rozdiel} = \sum |\text{Predikované} - \text{Aktuálne}|$$

**Vypočítané absolútne rozdiely sú:**

$$\text{Celkový absolútny rozdiel}(8) = 9 + 3 + 17 + 21 + 1 + 10 + 4 + 8 + 4 + 4 + 7 + 14 + 8 + 12 = 122$$

$$\text{Celkový absolútny rozdiel}(15) = 0.13 + 0.55 + 0.03 + 0.26 + 0.16 + 0.34 + 0.28 + 0.13 + 0.18 + 0.49 + 0.10 + 0.21 + 0.42 + 0.41 = 3.69$$

**Celkový skutočný predaj za dané obdobie:**

$$\text{Celkový skutočný predaj}(8) = 84 + 59 + 42 + 70 + 80 + 67 + 85 + 84 + 66 + 24 + 46 + 73 + 70 + 99 = 949$$

$$\text{Celkový skutočný predaj}(15) = 0.82 + 1.22 + 0.46 + 0.58 + 0.45 + 0.00 + 0.28 + 0.63 + 0.85 + 0.00 + 0.46 + 0.58 + 0.00 + 0.11 = 5.84$$

**Presnosť modelu sa potom vypočíta podľa vzorca:**

$$\text{Presnosť (8)} = 100\% - \left( \frac{\text{Celkový absolútny rozdiel}}{\text{Skutočný predaj}} \times 100 \right) \approx 100\% - \left( \frac{122}{949} \times 100 \right) \approx 87.14\%$$

$$\text{Presnosť (15)} = 100\% - \left( \frac{3.69}{5.84} \times 100 \right) \approx 36.81\%$$

### 8.1.3 Praktické dôsledky presnosti predpovedí

Kvantitatívne vyhodnotenie presnosti modelu pre Mrkváče a Klobásu Jablonickú v priebehu dvoch týždňov poskytuje jasný obraz o jeho prediktívnych schopnostiach. Zatiaľ čo úroveň presnosti, 87,14% pre Mrkváče a 36,81% pre Klobásu Jablonickú, môžu naznačovať rôzne stupne spoľahlivosti, je nevyhnutné zvážiť tieto výsledky v praktickom kontexte riadenia zásob.

Intervaly objednávaní zásob, ktoré sa môžu výrazne líšiť v závislosti od produktu – od denných až po mesačné – výrazne ovplyvňujú, ako presnosť predikcie ovplyvňuje prevádzkové rozhodnutia. Pri položkách ako Mrkváče a Klobása Jablonická, kde sa intervaly môžu predĺžiť až na 14 dní, môže aj stredná úroveň presnosti predikcie podstatne znížiť prevádzkové riziká. Presné predpovede konkrétne zabraňujú nadmernému zásobovaniu, ktoré môže viesť k zbytočným odpisom, a nedostatočnému zásobovaniu, ktoré môže frustrovať potenciálnych zákazníkov, ktorí majú záujem o kúpu produktu.

Pre Mrkváče bol skutočný celkový predaj 949 kusov, zatiaľ čo predpokladaný predaj bol 961 kusov, čo viedlo k malej percentuálnej chybe približne **1,26%**. V prípade Klobása Jablonická bol skutočný predaj 6,44 jednotiek s predikciou 6,96 jednotiek, čo viedlo k percentuálnej chybe približne **8,07%**.

## 8.2 Vyhodnotenie výsledkov prognózy pre experiment č.2

V druhom experimente boli predpovede predaja produktov vykonávané na základe obdobia ich trvanlivosti, respektívne na frekvencii ich objednávania. Konkrétne, predpovedané obdobie pre Tvaroh z Horehronia (ID: 5) bolo 17 dní, pre Balené párky (ID: 2) 21 dní a pre Rožtek makový (ID: 9) 7 dní. Chyba v predpovediach bola rôznorodá: **-3.84%** pre rožteky, **13.8%** pre párky a **21.1%** pre tvaroh. Tieto chyby poukazujú na variabilitu v presnosti modelu v závislosti na type produktu a dĺžke predpovedaného obdobia.

Hlavným zdrojom dát pre tento experiment boli ročné predajné údaje z roku 2023. Avšak, je potrebné zdôrazniť, že produkty zapojené do štúdie nemali vysokú dennú obrátku a v niektorých prípadoch dosahovali dokonca nulové predajné čísla. Napriek tomu, výsledky experimentu sú považované za sľubné. Ďalšie kroky by mali zahŕňať rozšírenie dátového setu o viacero ročných údajov a možno aj využitie techník na vyhladzovanie vstupných dát, aby sa zredukoval vplyv extrémov a zvýšila tak celková robustnosť a spoľahlivosť predpovedí.

## 8.3 Vyhodnotenie výsledkov prognózy pre experiment č.3

V rámci druhého experimentu boli hodnotené predikčné schopnosti modelu na produktoch Šunka slovenská (ID: 1) a Chlieb Dvojrunko kvasový (ID: 3) v predajniach Aupark, Šustekova a Slnčnice. Vyhodnotenie zahrnuje porovnanie skutočného predaja s predpokladaným predajom a výpočet percentuálnej chyby predikcií.

Model preukázal relatívne dobrú schopnosť predpovedať celkový predaj v danom období pre konkrétne predajne. Pri produktoch Šunka slovenská a Chlieb Dvojrunko kvasový sa percentuálne chyby celkového predaja pohybovali v rozmedzí od **-11.74%** do **-24.22%**. Tieto výsledky sa dajú považovať za sľubné, hlavne ak zväžíme význam predikcie celkového predaja z hľadiska zásobovania a plánovania.

Naopak, výsledky ukázali, že presnosť modelu pri predpovedaní konkrétnych denných predajov je nízka. Výkyvy v denných predikciách naznačujú, že model má tendenciu predpovedať hodnoty okolo priemeru, s väčšou odchýlkou od skutočných hodnôt. Táto skutočnosť je patrná najmä pri extrémnych hodnotách, ako sú maximálne a minimálne denné predaje, kde model značne podceňuje alebo preceňuje skutočný predaj. Percentuálne chyby pre tieto metriky dosiahli až **-69.40%** a **155.38%**, čo poukazuje na potrebu ďalšieho vývoja modelu pre zlepšenie jeho presnosti na dennom základe.

Z praktického hľadiska je schopnosť predpovedať celkový predaj významná, pretože umožňuje efektívnejšie riadenie zásob a môže pomôcť v minimalizácii odpisov z dôvodu prebytočných zásob. Avšak pre zlepšenie operatívneho rozhodovania a zvýšenie spokojnosti zákazníkov je nevyhnutné zvýšiť presnosť denných predpovedí, aby sa predchádzalo nedostatku alebo prebytku tovaru na konkrétne dni.

## 8.4 Porovnanie výsledkov s modelom aktuálne využívaného spoločnosťou

Z analýzy poskytnutých údajov zo spoločnosti Starý Otec a.s. som získal možnosť porovnať predikčné schopnosti tohto LSTM modelu s modelom, ktorý je v súčasnosti v prevádzke.

Pri tomto porovnávaní sa neberie do úvahy situácia, keď mohlo dôjsť k nedostatočným objednávkam, a preto nie je možné určiť potenciálny predaj, ak by bol k dispozícii väčší objem tovaru. Vyhodnotenie sa sústredilo na produkt Mrkváče, ktoré boli použité v prvom a zároveň najúspešnejšom experimente. Na základe objednávkovej frekvencie boli dáta projektované do sčítaných blokov vždy na určité obdobie. Výsledkom tohto porovnania za mesiac február 2024 bol absolútny rozdiel pre skutočné objednávky vo výške 196 a pre predpovedané hodnoty vo výške 103. Po výpočte z toho vyplýva, že presnosť aktuálneho modelu využívaného spoločnosťou je približne 89%, zatiaľ čo LSTM model dosahuje presnosť na úrovni 95%. Pre získanie ešte presnejších odhadov a výpočtov chýb by bolo vhodné uskutočniť detailnejšiu analýzu, ktorá by zahrnula aj dátové body s poddimenzovanými objednávkami, aby sa lepšie porozumelo kontextu a potenciálnym obmedzeniam oboch modelov.

Spoločnosť Starý Otec a.s. aktuálne eviduje chybovosť objednávkového systému v rozmedzí 4,8% až 12,5%, pričom analýza pre 10 produktov, pre 19 predajní zaberie človeku asi pol hodinu v závislosti od toho, ako podrobne rieši detaily. Oproti tomu, tento LSTM model vykázal v rámci testovania chyby v predpovediach predaja 1,26% (Mrkváče), 3,84% (Rožteky makové), 8,07% (Klobása Jablonická), 11,74% (Šunka slovenská), 12,61% (Chlieb dvojzrnko), 13,8% (Párky balené), 21,1% (Tvaroh), pričom predikcia produktu na natrénovanom modeli je otázkou 1-3 sekúnd.

## 8.5 Možnosti ďalšieho vývoja a vylepšení

Hoci výsledky tejto práce poskytujú pevný základ pre využitie LSTM modelov v predpovedi predaja v sektore FMCG, existuje niekoľko oblastí, ktoré ponúkajú príležitosti pre budúci výskum a vývoj. Jednou z kľúčových oblastí je integrácia LSTM s inými modelmi strojového učenia alebo kombinácia s rôznymi aktuálnymi prístupmi, aby sa vytvoril komplexnejší prediktívny systém. Takýto integrovaný prístup by mohol zahrnúť konvolučné neurónové siete na analýzu obrazových dát alebo strojové učenie na rozpoznávanie vzorcov v dátach o spotrebiteľskom správaní.

Ďalším smerom vývoja je rozšírenie vstupných parametrov modelu o faktory ako komplexnosť produktov, sezónnosť, marketingové akcie alebo dokonca socio-ekonomické indikátory, ktoré by mohli ovplyvniť dopyt po produktoch. Práca s komplexnejšími sádami dát, ktoré zahŕňajú tieto doplnujúce premenné, by mohla prispieť k presnejšiemu a robustnejšiemu predikčnému modelu.

V neposlednom rade je potrebné zdôrazniť potenciál pre prispôsobenie modelov pre real-time analýzu a predpovede, čo by umožnilo firmám reagovať na zmeny trhu v reálnom čase. To by mohlo mať veľký dopad na zlepšenie schopnosti adaptácie na meniace sa trhové podmienky a v konečnom dôsledku by to mohlo zvýšiť konkurencieschopnosť a ziskovosť podnikov v rámci sektora.

Budúci výskum by mal byť zameraný na testovanie týchto vylepšených modelov v rôznych podmienkach a na viacerých typoch produktov, aby sa overila ich všeobecná aplikovateľnosť a schopnosť prispôbiť sa rôznorodým predajným situáciám.

## Kapitola 9

# Záver

Táto práca sa zaoberala integráciou modelov strojového učenia do predajných procesov v sektore rýchloobrátkového spotrebného tovaru (FMCG) s dôrazom na predpovede predajnosti produktov. Tri hlavné experimenty boli navrhnuté tak, aby testovali účinnosť LSTM (Long Short-Term Memory) neurónových sietí pri predpovedaní predajných dát.

Model LSTM demonštruje značnú schopnosť využívať krátkodobé údaje na predpovedanie predaja, pričom efektívne zachytáva priemerné trendy aj dlhodobé závislosti predaja. Odchýlky v predpokladanom maximálnom a minimálnom predaji však naznačujú, že hoci je model zbehlý v identifikácii potenciálnych trendov, môžu byť potrebné úpravy na doladenie jeho citlivosti na odľahlé hodnoty a zriedkavé udalosti.

V záverečnej časti tohto výskumu sa ukázal významný potenciál modelu LSTM pri predpovedaní predaja konkrétneho produktu. Výsledky z Experimentu č. 1 ukazujú, že tento model dosiahol vysokú úroveň presnosti nielen v predpovedaní celkových predajov za dané obdobie, ale aj v denných predpovediach. Táto schopnosť presne predpovedať denné fluktuácie v predajoch je obzvlášť cenná, pretože umožňuje efektívnejšie plánovanie zásob a logistiku. Naopak, Experimenty č. 2 a č. 3, hoci taktiež preukázali uspokojivé výsledky v predpovedaní celkových predajov za obdobie, nedosiahli takú presnosť na dennom stupni predpovedí. Tento rozdiel v úspešnosti medzi experimentmi poukazuje na to, že výkon modelu LSTM môže kolísať v závislosti od špecifických charakteristík dát a nastavenia modelu. Tieto experimenty tiež naznačujú potrebu ďalšieho experimentovania a neustáleho vylepšovania celkového modelu, aby sa zvýšila presnosť denných predpovedí. Je dôležité zdôrazniť, že kvalita a charakteristika dát, z ktorých sa model učí, môžu mať významný vplyv na presnosť výsledných predpovedí. V prípade našich experimentov sa objavila situácia, keď boli historické objednávky často podhodnotené, čo mohlo viesť k tomu, že na daný deň sa skutočne predalo viac tovaru, než ukazovali záznamy. Tento typ dátového skreslenia môže model viesť k nepresným predpovediam, keďže model sa snaží naučiť vzory z nedokonalých alebo nereprezentatívnych dát. Riešením tohto problému je v prvom rade zlepšiť kvalitu vstupných dát, či už systematickým revíziám záznamov alebo implementáciou robustnejších systémov na zbieranie dát, ktoré presnejšie zachytávajú skutočný predaj.

Na základe výsledkov môžeme z praktického hľadiska konštatovať, že model je vhodný pre použitie v reálnych podmienkach. Vzhľadom na to, že produkty sa väčšinou objednávajú na niekoľkodňovej báze, dokáže tento model dobre predikovať predaje, ktoré sú následne použité ako základ pre objednávanie tovaru. V praxi by to mohlo znamenať značné zlepšenie v efektivite riadenia zásob, optimalizácii objednávacieho cyklu a minimalizácii odpadu, čo by mohlo viesť k zníženiu nákladov a zvýšeniu spokojnosti zákazníkov vďaka lepšej dostupnosti produktov.

Záverom možno povedať, že integrácia LSTM modelov do procesov FMCG sa ukazuje byť sľubnou cestou k dosiahnutiu vyššej úrovne automatizácie a inteligencie v predajných a distribučných reťazcoch. Výskum odhalil, že s primeraným nastavením a výberom relevantných dátových súradníc môže byť LSTM model cenným nástrojom pre predpovedné analýzy v tomto dynamickom sektore.

# Literatúra

- [1] *About Keras 3* online. Dostupné z: <https://keras.io/about/>.
- [2] Definition of 'neural network'. Dostupné z: <https://www.collinsdictionary.com/dictionary/english/neural-network>.
- [3] MICHAL PATÁK, L. B. a PECINOVA, Z. DEMAND FORECASTING IN RETAIL GROCERY STORES IN THE CZECH REPUBLIC. In.: 2015. Dostupné z: [https://www.researchgate.net/publication/312208849\\_DEMAND\\_FORECASTING\\_IN\\_RETAIL\\_GROCERY\\_STORES\\_IN\\_THE\\_CZECH\\_REPUBLIC](https://www.researchgate.net/publication/312208849_DEMAND_FORECASTING_IN_RETAIL_GROCERY_STORES_IN_THE_CZECH_REPUBLIC).
- [4] AAKARSHACHUG. *Deep Learning / Introduction to Long Short Term Memory*. 2023. Dostupné z: <https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/>.
- [5] ALZUBAIDI, Z. Y. *Á Comparative Study on Statistical and Machine Learning Forecasting Methods for an FMCG Company*. New York, USA, 2020. Thesis. Rochester Institute of Technology. Dostupné z: <https://repository.rit.edu/cgi/viewcontent.cgi?article=11870&context=theses>.
- [6] ARUNRAJ, N. S. a AHRENS, D. A Hybrid Seasonal Autoregressive Integrated Moving Average and Quantile Regression for Daily Food Sales Forecasting. *International Journal of Production Economics*, 2015.
- [7] BAELDUNG. Epoch in Neural Networks. *Baeldung on CS*, 2023. Dostupné z: <https://www.baeldung.com/cs/epoch-neural-networks>.
- [8] BROWNLEE, J. *A Gentle Introduction to Backpropagation Through Time* online. Dostupné z: [https://machinelearningmastery.com/gentle-introduction-backpropagation-time/?\\_\\_cf\\_chl\\_f\\_tk=R7U48ppzcrMRHsxlbdWzY9yWa\\_IPP6c6jBdgOXRzJjM-1714212883-0.0.1.1-1685](https://machinelearningmastery.com/gentle-introduction-backpropagation-time/?__cf_chl_f_tk=R7U48ppzcrMRHsxlbdWzY9yWa_IPP6c6jBdgOXRzJjM-1714212883-0.0.1.1-1685). [cit. 2024-04-27].
- [9] BROWNLEE, J. *How to Create an ARIMA Model for Time Series Forecasting in Python* online. Dostupné z: [https://machinelearningmastery.com/arima-for-time-series-forecasting-with-python/?\\_\\_cf\\_chl\\_f\\_tk=JyEGXEwm5aJkszxt8E.PzUR1K10KMXGHKQC5N1zbKjc-1701780472-0-gaNycGzNFLs](https://machinelearningmastery.com/arima-for-time-series-forecasting-with-python/?__cf_chl_f_tk=JyEGXEwm5aJkszxt8E.PzUR1K10KMXGHKQC5N1zbKjc-1701780472-0-gaNycGzNFLs). [cit. 2023-12-05].
- [10] BROWNLEE, J. *Semi-supervised learning with label Propagation* online. Dostupné z: <https://machinelearningmastery.com/semi-supervised-learning-with-label-propagation/>. [cit. 2024-02-22].

- [11] CIBULA, M. *Lineárna regresia, Algoritmy - Učenie s učiteľom* online. Dostupné z: <https://smnd.sk/mcibula/alg/linreg.html>. [cit. 2024-02-22].
- [12] DAOUD, M. Neurons, Activation Functions, Back-Propagation, Epoch, Gradient Descent: What are these? *Towards Data Science*, 2020. Dostupné z: <https://towardsdatascience.com/neurons-activation-functions-back-propagation-epoch-gradient-descent-what-are-these-c80349c6c452>.
- [13] DEVELOPERS scikit-learn. *Support Vector Machines* online. Dostupné z: <https://scikit-learn.org/stable/modules/svm.html#scores-probabilitiesSVM>. [cit. 2023-12-05].
- [14] DEVIN. *Understanding the basic Hierarchy of Artificial Intelligence* online. Dostupné z: [https://medium.com/@devin\\_chandula/understanding-the-ai-basic-hierarchy-b9d7438bff91](https://medium.com/@devin_chandula/understanding-the-ai-basic-hierarchy-b9d7438bff91). [cit. 2024-04-16].
- [15] FINEPROXY. *Feature scaling*. Dostupné z: <https://fineproxy.org/wiki/feature-scaling/>.
- [16] FRONZETTI, N. *Predictive Neural Network Applications for Insurance Processes*.
- [17] GODOY, J. N. V. *Demand forecasting of Fast Moving Consumer Goods based on modeling of time series and deep learning methods*. Bogotá, Colombia, 2022. Diplomová práca. Universidad Central/Universidad Jorge Tadeo Lozano. Dostupné z: <https://expeditiorepositorio.utadeo.edu.co/bitstream/handle/20.500.12010/27585/Tesis%20de%20Maestr%C3%ADa%202011-07-2022%20%28Jos%C3%A9%20Nicol%C3%A1s%20Valbuena%20Godoy%29.pdf?sequence=1&isAllowed=y>.
- [18] HAYES, A. *Multiple Linear Regression (MLR) Definition, Formula, and Example* online. Dostupné z: <https://www.investopedia.com/terms/m/mlr.asp>. [cit. 2023-12-05].
- [19] IAMTRASK. *A Neural Network in 13 lines of Python (Part 2 - Gradient Descent)*. Dostupné z: <https://iamtrask.github.io/2015/07/27/python-network-part2/>.
- [20] IBM. *Neural network image*. Dostupné z: [https://www.ibm.com/content/dam/connectedassets-adobe-cms/worldwide-content/cdp/cf/ul/g/3a/b8/ICLH\\_Diagram\\_Batch\\_01\\_03-DeepNeuralNetwork.png](https://www.ibm.com/content/dam/connectedassets-adobe-cms/worldwide-content/cdp/cf/ul/g/3a/b8/ICLH_Diagram_Batch_01_03-DeepNeuralNetwork.png).
- [21] IBM. *What are recurrent neural networks?* IBM. Dostupné z: <https://www.ibm.com/topics/recurrent-neural-networks>.
- [22] INSTITUTE, C. F. *Fast-Moving Consumer Goods (FMCG)* online. Dostupné z: <https://corporatefinanceinstitute.com/resources/valuation/fast-moving-consumer-goods-fmcg/>. [cit. 2023-11-07].
- [23] KENTON, W. *Fast-Moving Consumer Goods (FMCG) Industry: Definition, Types, and Profitability* online. Dostupné z: <https://www.investopedia.com/terms/f/fastmoving-consumer-goods-fmcg.asp>. [cit. 2024-04-27].
- [24] KOSTADINOV, S. *Understanding GRU Networks* online. Dostupné z: <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>. [cit. 2024-02-22].

- [25] LABS, S. *Understanding Deep Learning: DNN, RNN, LSTM, CNN and R-CNN* online. Dostupné z: <https://medium.com/@sprhllabs/understanding-deep-learning-dnn-rnn-lstm-cnn-and-r-cnn-6602ed94dbff>. [cit. 2024-04-16].
- [26] LINKEDIN. *What are the advantages and disadvantages of using ARIMA models for forecasting?* online. Dostupné z: <https://www.linkedin.com/advice/0/what-advantages-disadvantages-using-arma>. [cit. 2023-12-05].
- [27] LOPEZ dProgrammer. *RNN, LSTM & GRU* online. Dostupné z: <http://dprogrammer.org/rnn-lstm-gru>. [cit. 2023-11-07].
- [28] *LSTM layer*. Dostupné z: [https://keras.io/api/layers/recurrent\\_layers/lstm/](https://keras.io/api/layers/recurrent_layers/lstm/).
- [29] MARTA GOŁĄBEK, R. S. a NEUMANN, R. *Demand Forecasting using Long Short-Term Memory Neural Networks*, 2020.
- [30] MATERNA, J. *Konvergence algoritmu k-means* online. Dostupné z: <http://www.mlgyuru.com/cs/konvergence-algoritmu-k-means/>. [cit. 2024-02-22].
- [31] MURÁŇ, I. J. *Úvod do neuronových sietí. Umelá Inteligencia.sk*, 2019.
- [32] NBRO. *What is the difference between LSTM and RNN?* online. Dostupné z: <https://ai.stackexchange.com/questions/18198/what-is-the-difference-between-lstm-and-rnn>. [cit. 2024-04-16].
- [33] NELSON, D. *Co je to rozhodovací strom?* online. Dostupné z: <https://www.unite.ai/cs/co-je-rozhodovac%C3%AD-strom/>. [cit. 2023-12-05].
- [34] POWERS, J. *Gradient Descent in Machine Learning: A Basic Introduction* online. Dostupné z: <https://builtin.com/data-science/gradient-descent>. [cit. 2024-04-27].
- [35] PYTHON.ORG. *What is Python? Executive Summary* online. Dostupné z: <https://www.python.org/doc/essays/blurb/>. [cit. 2024-04-16].
- [36] RAY, S. *Understanding and coding Neural Networks From Scratch in Python and R*. 2020. Dostupné z: <https://medium.com/analytics-vidhya/understanding-and-coding-neural-networks-from-scratch-in-python-and-r-b8c760f0ad1c>.
- [37] SAPORITO, G. *What is a perceptron? Towards Data Science*, 2019. Dostupné z: <https://towardsdatascience.com/what-is-a-perceptron-210a50190c3b>.
- [38] SILAPARASETTY, V. *What are some of the challenges and limitations of RNNs?* online. Dostupné z: <https://www.linkedin.com/advice/1/what-some-challenges-limitations-rnns>. [cit. 2024-04-16].
- [39] TABSHARANI, F. *Types of AI algorithms and how they work* online. Dostupné z: <https://www.techtarget.com/searchenterpriseai/tip/Types-of-AI-algorithms-and-how-they-work>. [cit. 2024-02-18].
- [40] TEAM, M. S. *Top 10 FMCG Companies in the World 2023* online. Dostupné z: <https://www.mbaskool.com/business-lists/top-brands/17609-top-10-fmcg-companies-in-the-world.html>. [cit. 2023-11-07].



- [41] WAIDA, M. *What are the four sales forecasting methods?* online. Dostupné z: <https://www.nutshell.com/blog/sales-forecasting-methods>. [cit. 2023-12-05].
- [42] ZVORNICANIN, E. *Bias Update in Neural Network Backpropagation*. Dostupné z: <https://www.baeldung.com/cs/deep-learning-bias-backpropagation>.

# Príloha A

## LSTM Keras

### LSTM

Keras vrstva LSTM [28] :

```
1 keras.layers.LSTM(  
2     units,  
3     activation="tanh",  
4     recurrent_activation="sigmoid",  
5     use_bias=True,  
6     kernel_initializer="glorot_uniform",  
7     recurrent_initializer="orthogonal",  
8     bias_initializer="zeros",  
9     unit_forget_bias=True,  
10    kernel_regularizer=None,  
11    recurrent_regularizer=None,  
12    bias_regularizer=None,  
13    activity_regularizer=None,  
14    kernel_constraint=None,  
15    recurrent_constraint=None,  
16    bias_constraint=None,  
17    dropout=0.0,  
18    recurrent_dropout=0.0,  
19    seed=None,  
20    return_sequences=False,  
21    return_state=False,  
22    go_backwards=False,  
23    stateful=False,  
24    unroll=False,  
25    **kwargs  
26 )
```

### Argumenty LSTM

- **units**: Kladné celé číslo, dimenzionalita výstupného priestoru.
- **activation**: Aktivačná funkcia na použitie. Predvolené: hyperbolický tangens (*tanh*). Ak zadáte *None*, žiadna aktivácia sa nepoužije (tj. "lineárna aktivácia:  $a(x) = x$ ).

- **recurrent\_activation**: Aktivačná funkcia na použitie pre rekurentný krok. Predvolené: sigmoid (*sigmoid*). Ak zadáte *None*, žiadna aktivácia sa nepoužije (tj. "lineárna aktivácia:  $a(x) = x$ ").
- **use\_bias**: Boolovská hodnota, (predvolené *True*), či by vrstva mala používať vektor sklonu.
- **kernel\_initializer**: Inicializátor pre maticu váh jadra, používaný na lineárnu transformáciu vstupov. Predvolené: "glorot\_uniform".
- **recurrent\_initializer**: Inicializátor pre maticu váh rekurentného jadra, používaný na lineárnu transformáciu rekurentného stavu. Predvolené: "orthogonal".
- **bias\_initializer**: Inicializátor pre vektor sklonu. Predvolené: "zeros".
- **unit\_forget\_bias**: Boolovská hodnota (predvolené *True*). Ak *True*, pridá 1 k sklonu brány zabúdania pri inicializácii. Nastavenie na *True* tiež vyžaduje *bias\_initializer="zeros"*. Toto sa odporúča v Jozefowicz et al.
- **kernel\_regularizer**: Funkcia regularizátora aplikovaná na maticu váh jadra. Predvolené: *None*.
- **recurrent\_regularizer**: Funkcia regularizátora aplikovaná na maticu váh rekurentného jadra. Predvolené: *None*.
- **bias\_regularizer**: Funkcia regularizátora aplikovaná na vektor sklonu. Predvolené: *None*.
- **activity\_regularizer**: Funkcia regularizátora aplikovaná na výstup vrstvy (jej aktiváciu). Predvolené: *None*.
- **kernel\_constraint**: Funkcia obmedzenia aplikovaná na maticu váh jadra. Predvolené: *None*.
- **recurrent\_constraint**: Funkcia obmedzenia aplikovaná na maticu váh rekurentného jadra. Predvolené: *None*.
- **bias\_constraint**: Funkcia obmedzenia aplikovaná na vektor sklonu. Predvolené: *None*.
- **dropout**: Float medzi 0 a 1. Zlomok jednotiek na vypadnutie pre lineárnu transformáciu vstupov. Predvolené: 0.
- **recurrent\_dropout**: Float medzi 0 a 1. Zlomok jednotiek na vypadnutie pre lineárnu transformáciu rekurentného stavu. Predvolené: 0.
- **seed**: Náhodný seed pre vypadnutie.
- **return\_sequences**: Boolovská hodnota. Či vrátiť posledný výstup v výstupnej postupnosti, alebo celú postupnosť. Predvolené: *False*.
- **return\_state**: Boolovská hodnota. Či vrátiť posledný stav okrem výstupu. Predvolené: *False*.

- **go\_backwards**: Boolovská hodnota (predvolené: *False*). Ak *True*, spracuje vstupnú sekvenciu v opačnom poradí a vráti pretočenú sekvenciu.
- **stateful**: Boolovská hodnota (predvolené: *False*). Ak *True*, posledný stav pre každý vzor na indexe *i* v dávke bude použitý ako počiatočný stav pre vzor na indexe *i* v nasledujúcej dávke.
- **unroll**: Boolovská hodnota (predvolené *False*). Ak *True*, sieť bude odvinutá, inak sa použije symbolická slučka. Odvinutie môže zrýchliť rekurentnú neurónovú sieť, hoci tenduje byť pamätovo náročnejšie. Odvinutie je vhodné iba pre krátke sekvencie.