



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV INFORMATIKY

INSTITUTE OF INFORMATICS

VYUŽITÍ SOFT COMPUTINGU V RÁMCI ŘÍZENÍ OBJEDNÁVKOVÉHO CYKLU

THE UTILIZATION OF SOFT COMPUTING IN ORDERING CYCLE MANAGEMENT

DIZERTAČNÍ PRÁCE

DOCTORAL THESIS

AUTOR PRÁCE

AUTHOR

Ing. TEREZA ŠUSTROVÁ

VEDOUCÍ PRÁCE

SUPERVISOR

prof. Ing. PETR DOSTÁL, CSc.

BRNO 2016

Vysoké učení technické v Brně, Fakulta podnikatelská

Akademický rok: 2015/16

ZADÁNÍ DIZERTAČNÍ PRÁCE

student(ka): Ing. Tereza Šustrová

který/která studuje v **doktorském studijním programu**

obor: **Řízení a ekonomika podniku (6208V097)**

Téma dizertační práce:

Využití Soft Computingu v rámci řízení objednávkového cyklu

v anglickém jazyce:

The Utilization of Soft Computing in Ordering Cycle Management

Stručná charakteristika problematiky úkolu:

Úvod

Cíle dizertační práce

Metodologie zpracování dizertační práce

Zhodnocení současného stavu řešené problematiky

Výsledky dizertační práce

Přínosy dizertační práce

Závěr

Seznam použité literatury

Seznam příloh

Cíle dizertační práce:

Hlavním cílem dizertační práce je navrhnout model pro optimální objednávkový cyklus společnosti pro zajištění plynulého materiálového toku v organizaci působící v oblasti obchodního podnikání za použití metod umělé inteligence.

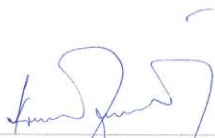
Seznam odborné literatury:

- ARLT, J. a ARLTOVÁ, M. Ekonomické časové řady: [vlastnosti, metody modelování, příklady a aplikace]. 1. vyd. Praha: Grada. 2007. ISBN 978-80-247-1319-9.
- BAILY, P. J. et al. Purchasing principles and management. 9th ed. Harlow: Financial Times Prentice Hall, 2005. xiv, 427 s. ISBN 0-273-64689-3.
- CIPRA, T. Analýza časových řad s aplikacemi v ekonomii: celostátní vysokoškolská učebnice pro stud. matem.-fyz. fakult studijních oborů 11 Fyzikálně matematické vědy. 1. vyd. Praha: Státní nakladatelství technické literatury. 1986. ISBN 04-012-86.
- DOSTÁL, P. Soft computing v podnikatelství a veřejné správě: Díl I. Vydání první. Brno: Akademické nakladatelství CERM. 2015.
- HORÁKOVÁ, H. Řízení zásob: Logistické pojetí, metody, aplikace, praktické úlohy. 3.přepř.vyd. Praha: Profess Consulting. 1998. 236 s. ISBN 80-852-3555-2.
- CHOPRA, S., MEINDL, P. Supply chain management: strategy, planning, and operation. 3rd ed. Upper Saddle River: Pearson Prentice Hall, c2007. xv, 536 s. ISBN 0-13-173042-8.
- PERNICA, P. Logistika pro 21. století: (Supply chain management). Vyd. 1. Praha: Radix, 2005. ISBN 80-860-3159-4.
- TETTAMANZI, Andrea a Marco TOMASSINI. Soft computing: integrating evolutionary, neural, and fuzzy systems. New York: Springer, c2001. xiii, 328 p. ISBN 35-404-2204-8.


Vedoucí dizertační práce: prof. Ing. Petr Dostál, CSc.

Termín odevzdání dizertační práce je stanoven časovým plánem akademického roku 2015/16.

V Brně, dne 14. 3. 2016



Předseda oborové rady



Děkan

Abstrakt

Dizertační práce se zabývá možnostmi využití pokročilých metod rozhodování - Soft Computingu při řízení objednávkového cyklu podniku. Hlavním cílem dizertační práce je navržení modelu umělé neuronové sítě s optimální architekturou pro řízení objednávkového cyklu podniku v rámci řízení dodavatelského řetězce. Vytvořený model bude sloužit v organizaci působící v oblasti obchodního podnikání pro zajištění plynulého materiálového toku.

Součástí dizertační práce je rovněž konstrukce a ověření modelu umělé neuronové sítě pro predikci prodeje a srovnání výsledků a vhodnosti použití s běžnými a dosud používanými statistickými metodami. Dále se dizertační práce zabývá nalezením vhodné architektury umělé neuronové sítě pro stanovení velikosti objednávky na základě zadaných vstupů.

Ke zpracování modelu bylo využito metod statistického zpracování dat, ekonomického modelování, Soft Computingu a poznatků ohledně stavu vědeckého poznání řešené problematiky z posledních let.

Klíčová slova

Objednávkový cyklus podniku

Soft Computing

Umělé neuronové sítě

Řízení dodavatelského řetězce

Řízení zásob

Velikost objednávky

Abstract

This doctoral thesis deals with possibilities of using advanced methods of decision-making - Soft Computing, in company's ordering cycle management. The main aim of the thesis is to propose an artificial neural network model with an optimal architecture for ordering cycle management within the supply chain management. The proposed model will be employed in an organization involved in retailing to ensure smooth material flow.

A design and verification of artificial neural networks model for sales prediction is also part of this doctoral thesis as well as a comparison of results and usability with standard and commonly used statistical methods. Furthermore, the thesis deals with finding a suitable artificial neural network model with architecture capable of solving the lot-size problem according to specified inputs.

Methods of statistical data processing, economical modelling and advanced decision-making (Soft Computing) were utilized during the model designing process.

Keywords

Company's Ordering Cycle

Soft Computing

Artificial Neural Network

Supply Chain Management

Inventory Management

Lot-Sizing Problem

Bibliografická citace dizertační práce

ŠUSTROVÁ, T. *Využití Soft Computingu v rámci řízení objednávkového cyklu*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2015. 118 s. Vedoucí dizertační práce: prof. Ing. Petr Dostál, CSc.

Čestné prohlášení

Prohlašuji, že předložená dizertační práce s názvem *Využití Soft Computingu v rámci řízení objednávkového cyklu* je původní a zpracovala jsem ji samostatně pod vedením mého školitele. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušila autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně, dne 11. dubna 2016

.....

Ing. Tereza Šustrová

Poděkování

Ráda bych touto cestou poděkovala svému školiteli prof. Ing. Petru Dostálovi, CSc. za odborné vedení a cenné rady a připomínky při vypracování této dizertační práce jakož i v průběhu celého doktorského studia.

Také bych chtěla poděkovat doc. RNDr. Bedřichu Půžovi, CSc., řediteli Ústavu informatiky Fakulty podnikatelské VUT v Brně, za vytvoření výborných studijních podmínek a příležitostí pro doktorském studium a psaní této dizertační práce. Velké díky patří kolegům a doktorandům nejen Ústavu informatiky za podporu při doktorském studiu.

Zvláštní poděkování bych chtěla věnovat kolegyni Mgr. Veronice Novotné, Ph.D. za spolupráci a vedení ve světě vědy a výzkumu a rovněž v pedagogické oblasti, ale i za podporu v osobním i profesním životě.

Dále bych chtěla poděkovat spolupracující společnosti HPM Tec, s.r.o., především jejímu zástupci Ing. Lubomíru Karpíškovi za poskytnutá data a informace z oblasti podnikatelské praxe k vypracování této práce.

Obsah

Úvod.....	14
1 Cíle dizertační práce	16
1.1 Stanovení cíle práce	16
2 Metodologie zpracování dizertační práce.....	17
2.1 Metody vědeckého zkoumání	17
2.2 Metody sběru dat.....	20
2.3 Model a modelování.....	21
2.3.1 Klasifikace modelů.....	21
2.4 Metody Soft Computingu.....	22
2.4.1 Fuzzy množiny a fuzzy logika.....	22
2.4.2 Umělé neuronové sítě	24
2.4.3 Genetické algoritmy	29
2.5 Metody analýzy dat	30
2.5.1 Regresní analýza.....	30
2.5.2 Korelační analýza	32
2.5.3 Analýza časových řad.....	33
2.5.4 Přístupy k modelování časových řad.....	34
2.5.5 Klouzavé průměry	35
2.5.6 Sezónní očištění.....	36
2.5.7 Box-Jenkinsonova metodologie	37
2.6 Postup řešení dizertační práce	39
3 Zhodnocení současného stavu řešené problematiky.....	41
3.1 Řízení dodavatelského řetězce	41
3.1.1 Procesní pohled na dodavatelský řetězec	41
3.1.2 Makro procesy dodavatelského řetězce.....	44

3.1.3	Vývojové typy dodavatelského řetězce	44
3.2	Zásobování a náklady.....	46
3.3	Řízení zásob v obchodě.....	46
3.4	Modely řízení cyklu zásob	48
3.4.1	Klasifikace zásob.....	48
3.4.2	Klasifikace modelů řízení cyklu zásob.....	49
3.4.3	Modely deterministické.....	51
3.4.4	Modely stochastické	54
3.4.5	Q-systém.....	56
3.4.6	P-systém	57
3.5	Současné trendy modelů pro řízení zásob	59
3.6	Současné trendy v predikci časových řad pomocí Soft Computingu....	60
3.7	Soft Computing při řízení zásob	63
3.7.1	Fuzzy logika a další pokročilé metody rozhodování.....	63
3.7.2	Využití umělých neuronových sítí pro řízení zásob.....	65
4	Výsledky dizertační práce	68
4.1	Popis aktuálního stavu analyzované společnosti.....	68
4.2	Analýza časové řady	69
4.2.1	Sezónní očištění.....	70
4.2.2	Trendové očištění	72
4.2.3	Časová řada očištěná od sezónnosti a trendu	73
4.3	Transformace dat.....	73
4.4	Umělá neuronová síť pro predikci prodeje	74
4.4.1	Predikce prostřednictvím umělých neuronových sítí	74
4.4.2	Srovnání modelu umělé neuronové sítě a statistických metod.....	79
4.5	Neuronová síť pro řízení objednávkového cyklu.....	81

4.5.1	Proměnné modelu umělé neuronové sítě.....	81
4.5.2	Architektura modelu umělé neuronové sítě.....	84
4.5.3	Výsledky modelu neuronové sítě	87
4.6	Model řízení objednávkového cyklu.....	90
4.6.1	Ověření použitelnosti modelu řízení objednávkového cyklu	92
4.7	Ověření návrhů pro další typ zboží	94
4.8	Metodika pro využití navrženého modelu.....	97
5	Přínosy dizertační práce	98
5.1	Teoretická oblast	98
5.2	Praktická oblast	99
5.3	Pedagogická oblast.....	100
6	Závěr.....	101
7	Seznam použitých zdrojů	103
	Seznam použitých zkratk a symbolů	113
	Seznam grafů.....	115
	Seznam obrázků	116
	Seznam tabulek	117
	Seznam příloh	118

Úvod

V dnešním silně konkurenčním prostředí, vyznačujícím se nízkými ziskovými maržemi, vysokými požadavky spotřebitelů na kvalitu výrobků a krátké dodací lhůty, jsou podniky nuceny využít každé příležitosti k optimalizaci jejich obchodních procesů. (Aissaoui, Houari a Hassini, 2007)

Problematika řízení zásob je považována za jednu z nejdůležitějších funkcí výrobních i obchodních podniků a má poměrně často vliv na celkovou výkonnost podnikání. Velmi často je potřeba na jedné straně vzít v úvahu kompromis mezi úrovní skladovacích nákladů a na druhé straně pak vysoké náklady na ztráty vyplývající z nízké úrovně zásob a nemožnosti uspokojit zákazníka. Optimální řešení spočívá v účinném způsobu řízení zásob, který zaručí dobrou úroveň služeb bez nadměrně velkých zásob, které neúměrně zvyšují skladovací náklady. (Nenes, Panagiotidou a Tagaras, 2010)

Teorie řízení zásob je pravděpodobně jednou z nejvíce prozkoumaných oblastí ve výrobě a obchodu. I když se téměř všechny velké výrobní či obchodní podniky a mnohé malé a střední firmy snaží stále více aplikovat vědecké metody pro lepší správu svých zásob, použití těchto metod je často omezeno na několik základních nástrojů, jako je výpočet ekonomického množství k objednání, určení bodů přioobjednání či minimální zásoby pro zachování požadované úrovně služeb. (Nenes, Panagiotidou a Tagaras, 2010)

Úkolem modelů řízení zásob je vhodným způsobem regulovat aktuální stav zásob, nejčastěji s ohledem na výši skladovacích či objednacích nákladů. Dosud však nebyl vyvinut vhodný model pro řízení zásob jako univerzální řešení, tím pádem je nutné v každé specifické situaci najít optimální řešení modelu zásob jakožto derivát již existujících modelů.

Technika umělých neuronových sítí se zdá být slibným nástrojem pro optimalizaci úrovně zásob v oblasti obchodního podnikání. Umělé neuronové sítě jsou schopny zachytit složité vstupně-výstupní vztahy bez nutnosti pomoci matematického modelu. Bývají často využity pro modelování komplikovaných procesů, a to díky jejich schopnosti učení a vyvozování obecných závěrů, možnosti pracovat s nelineárními proměnnými, přizpůsobení se změnám okolního prostředí a odolnosti vůči chybějícím

datům. Schopnost přizpůsobit se vnějšímu prostředí znamená, že model umělé neuronové sítě je vhodné použít také pro řešení otázky řízení zásob, kdy podléhají vstupní parametry, jako například podmínky v oboru podnikání, typ produktu, požadavky zákazníka, častým změnám. (Paul a Azeem, 2011)

Dizertační práce se věnuje problematice současných modelů pro objednávkový cyklus v rámci řízení dodavatelského cyklu podniku pro zajištění plynulého materiálového toku. V rámci práce je řešena otázka, jakým způsobem je možné využít metod Soft Computingu, konkrétně metod a modelování umělých neuronových sítí v této oblasti. Předkládaná práce je zaměřena na návrh objednávkového cyklu podniku s využitím metod Soft Computingu, konkrétně umělých neuronových sítí.

1 Cíle dizertační práce

1.1 Stanovení cíle práce

Hlavním cílem dizertační práce je navrhnout model pro optimální objednávkový cyklus společnosti pro zajištění plynulého materiálového toku v organizaci působící v oblasti obchodního podnikání za použití metod umělé inteligence.

Pro dosažení hlavního cíle práce je potřeba splnění následujících **dílčích cílů** práce:

- Identifikace klíčových faktorů z oblasti dodavatelského řetězce obchodních společností k vytvoření modelu.
- Provedení analýzy současného stavu řešené problematiky v oblasti řízení objednávkového cyklu a metod umělé inteligence.
- Zvolení vhodných metod z oblasti Soft Computingu a jejich aplikace při tvorbě modelu.
- Vytvoření modelu pro řízení objednávkového cyklu podniku.
- Verifikace správnosti modelu a přínosů pro zvolený podnik.
- Sestavení metodiky pro využití vytvořeného modelu v praxi či v dalším výzkumu.

2 Metodologie zpracování dizertační práce

K vypracování dizertační práce a naplnění hlavního a dílčích cílů bude využívána celá řada metod. V první řadě bych chtěla vyzdvihnout nutnost využití systémového přístupu při plnění všech úkolů vedoucích ke zdárnému zpracování dizertační práce.

Systémový přístup je dle RAISE a DOSKOČILA (2011, str. 12 a 13) „*způsob myšlení, řešení úloh a jednání, při němž jsou jevy chápány v jejich vnitřních i vnějších souvislostech, tedy komplexně.*“ V souvislosti se systémovým přístupem je nutné se při řešení problému důsledně zaměřit na respektování vazeb mezi prvky, které vstupují do úlohy.

Další vhodnou metodou je metoda **plánování výzkumu**, kterou je potřeba použít ještě před začátkem samotného výzkumného procesu. Jednotlivými možnými kroky jsou:

1. Formulace a vymezení problému a s tím související volba tématu, názvu a cíle dizertační práce.
2. Shromáždění a studium dostupných zdrojů.
3. Vymezení cíle výzkumu a v případě potřeby také hypotéz na základě cíle dizertační práce.
4. Volba výzkumných metod v souvislosti s cíli výzkumu a stanovenými hypotézami, jsou-li stanoveny.
5. Shromáždění dat, jejich analýza, provedení výpočetních postupů.
6. Formulace závěru a prezentace výsledků. (Molnár, 2011, str. 4)

2.1 Metody vědeckého zkoumání

Metody vědecké práce lze rozdělit do dvou skupin:

- A. Empirické metody nebo také metody sběru dat:
 - pozorování, dotazování
 - měření
 - experimentování
- B. Logické metody:
 - analýza a syntéza

- indukce a dedukce
- abstrakce a konkretizace (Molnár, 2011, str. 6)

Pozorování

Pozorování je cílevědomé, plánovité a systematické sledování určitých skutečností. Je to metoda, kdy jsou informace získávány bezprostředním smyslovým vnímáním. Pozorování probíhá bez přímého kontaktu mezi pozorovaným a pozorovatelem (nekladou se tedy otázky, pouze sledujeme chování). Je to nejuniverzálnější metoda, která poskytuje prvotní informace o sledovaném jevu či objektu a je většinou základem každé výzkumné metody. (Široký, 2010, str. 17)

Dotazování

Smyslem dotazování je kladení otázek respondentům, obvykle prostřednictvím dotazníku. Dotazy lze pokládat formou osobní, písemnou, elektronickou či telefonickou. Dotazováním jsou získávána cenná data od cílové skupiny výzkumu.

Experimentování

Experiment je pokus, kdy je realizován takový postup a způsob, který je záměrně navozen. Experiment je pozorováním za kontrolovaných či řízených podmínek. (Široký, 2010, str. 17)

Analýza a syntéza

Analýza je metodický postup poznání od celku k částem. Jestliže systém jako celek vykazuje určité chování, pak se toto chování musí dát vysvětlit chováním jeho prvků v dané struktuře. (Rais a Doskočil, 2011, str. 14) Syntéza je myšlenkové spojení jednotlivých částí (prvků systému) v celek.

Syntéza a analýza jsou sice protikladné způsoby zkoumání, ve skutečnosti se však vzájemně doplňují, a tak se také někdy souhrnně nazývají analyticko-syntetickými poznávacími postupy. Syntéza totiž mnohdy není možná bez analýzy a naopak. (Široký, 2010, str. 17 a 18)

Získána data od spolupracující společnosti jsou podrobena analýze - nejdříve zběžné analýze charakterizující povahu získaných dat a následně analýze časových řad. Také data získaná literární rešerší byla analyzována a na jejím základě byly vyhodnoceny poznatky zkoumané problematiky. Syntéza je využita při formulování závěru.

Indukce a dedukce

Indukce je proces vyvozování obecného závěru na základě poznatků o jednotlivostech. Indukce zajišťuje přechod od jednotlivých soudů k obecným. Závěry induktivních myšlenkových pochodů jsou vždy ovlivněny subjektivními postoji (zkušenostmi, znalostmi) a mají proto omezenou platnost.

Dedukce je způsob myšlení, při němž od obecných závěrů, tvrzení a soudů přecházíme k méně známým. Vycházíme tedy ze známých, ověřených a obecně platných závěrů a aplikujeme je na jednotlivé dosud neprozkoumané případy. Dedukce je proces, ve kterém testujeme, zda vyslovený předpoklad je schopen vysvětlit zkoumaný fakt. (Molnár, 2011, str. 7)

Indukcí lze dospět na základě zkoumání jednotlivých, zejména empirických jevů k teoretickým zobecněním, teoretické závěry lze naopak dedukcí v praxi ověřovat. (Široký, 2010, str. 18)

Indukce je využita při konstrukci modelu umělé neuronové sítě pro predikci měsíčních prodejů a taktéž při konstrukci modelu pro řízení objednávkového cyklu podniku na základě dříve zjištěných poznatků. Dedukce pak při ověření správnosti navrženého modelu.

Abstrakce a konkretizace

Abstrakce je myšlenkový proces, v jehož rámci se u různých objektů vydělují pouze jejich podstatné charakteristiky (nepodstatné se neuvažují), čímž se ve vědomí vytváří model objektu obsahující jen ty charakteristiky či znaky, jejichž zkoumání nám umožní získat odpovědi na otázky, které si klademe.

Konkretizace je opačný proces, kdy vyhledáváme konkrétní výskyt určitého objektu z určité třídy objektů a snažíme se na něj aplikovat charakteristiky platné pro tuto třídu objektů. (Molnár, 2011, str. 6 a 7)

Abstrakce je využita při identifikaci vstupů, pro model umělé neuronové sítě pro řízení objednávkového cyklu podniku, tedy pro určení nejdůležitějších faktorů ovlivňujících rozhodnutí o objemu objednávaného zboží. Na základě konkretizace byly verifikovány výstupy modelu.

2.2 Metody sběru dat

Obecně se pro shromažďování dat, ať už primárních či sekundárních, používají následující metody:

- *Pozorování* – je nepřímým nástrojem sběru dat, protože nevyžaduje přímý kontakt se zkoumanými subjekty a není závislé na ochotě respondentů spolupracovat. Podstatou pozorování je záměrné, cílevědomé a plánované sledování právě probíhajících skutečností, aniž by pozorovatel nějak aktivně zasahoval. V roli pozorovatele vystupuje zpravidla člověk, který často využívá různé technické pomůcky (kamery, magnetofony, chronometry atd.) (Kozel, 2011, str. 178 - 181)
- *Dotazování* – jde o metodu sběru primárních dat založenou na přímém (rozhovor) nebo nepřímém (dotazník) kontaktu mezi výzkumníkem a respondentem podle předem předepsané formy otázek, jež slouží ke sjednocování podmínek a usnadnění zpracování výsledků. Existuje více typů dotazování, jako osobní dotazování, telefonické dotazování, online dotazování, přímé dotazování, skupinové interview apod. Výběr vhodného typu dotazování závisí na různých faktorech, především na charakteru a rozsahu zjišťovaných dat, skupině respondentů, časových a finančních limitech, kvalifikaci tazatele atd. V praxi se jednotlivé typy navzájem kombinují. (Kozel, 2011, str. 175 - 178)
- *Experiment* – v rámci experimentu je využíváno experimentální a kontrolní skupiny. V průběhu experimentu se v souhrnu daných podmínek, vytvářejících prostředí experimentu, zavede určitý testovaný prvek a výsledek působení se pozoruje a měří na jiném prvku. Mezi experimenty řadíme laboratorní experiment, terénní experiment či online experiment. (Kozel, 2011, str. 181 - 183)
- *Sběr dokumentů* – dokumenty mohou tvořit jediný datový podklad studie nebo doplňují data získaná pozorováním a rozhovory. Za dokumenty se považují taková data, která vznikla v minulosti, byla pořízena někým jiným než výzkumníkem a pro jiný účel, než jaký má aktuální výzkum. Rozlišujeme osobní dokumenty, úřední dokumenty, archivní data, výstupy masových médií a virtuální data. (Hendl, 2008, str. 204)

Z metod sběru dat byla při zpracování dizertační práce pro analýzu současného stavu řešené problematiky využita sekundární data získaná pomocí rešerše literatury.

V rámci praktické části dizertační práce bylo využito pozorování a dotazování, které proběhlo v místě podnikání firmy poskytující vstupní data. Dále byl proveden sběr sekundárních dat, a to údajů o prodejkách a dalších důležitých dat která byla následně využita pro určení vstupů do modelu umělé neuronové sítě pro optimalizaci objednávkového cyklu podniku.

2.3 Model a modelování

Dle RAISE A DOSKOČILA (2011, str. 17) je model *„zjednodušené zobrazení reality, na kterém se dají studovat vlastnosti, které jsou z hlediska studovaného jevu významné. Modelování je postup od objektivní reality k modelu.“*

Ekonomické modely jsou využívány ke znázornění vztahů mezi proměnnými. Mohou být formulovány verbálně, graficky nebo algebraicky. Díky tomu, že zjednodušují ekonomickou realitu a zachycují vztahy pouze mezi zvolenými proměnnými, umožňují porozumět základním ekonomickým jevům a vztahům mezi nimi. (Hořejší, 2010, str. 21)

Konstrukci ekonomických modelů předchází přijetí zjednodušujících předpokladů. Ty umožňují u zkoumaného problému soustředit pozornost na klíčové aspekty, resp. definují charakteristické rysy chování zkoumaných ekonomických jednotek. (Hořejší, 2010, str. 21)

Matematický model lze chápat jako vyjádření ekonomického modelu matematickými prostředky. U matematického modelu hraje velmi důležitou roli výběr nejvhodnějšího a zároveň nejjednoduššího nástroje. (Fábry, 2011, str. 11)

2.3.1 Klasifikace modelů

Deterministické a stochastické modely

V deterministických modelech jsou veškeré informace o zkoumaném systému známy s jistotou, zatímco ve stochastických modelech se některé procesy či hodnoty řídí zákony pravděpodobnostního charakteru. U deterministického modelu je známa jeho struktura, která může být popsána třeba algebraickou nebo diferenciální rovnicí. Pro stochastické modely je charakteristické, že dovolují poměrně přesnou matematickou manipulaci se vztahy mezi veličinami, i když ve skutečnosti platí tyto vztahy pouze

přibližně. Stochastický model můžeme vyjádřit jako rovnici nebo soustavu rovnic obsahující mimo jiné také náhodné veličiny.

Statické a dynamické modely

Pokud ve zkoumaném systému hraje významnou roli čas, je nutné použít dynamický model, v opačném případě se použije statický model. Lze konstatovat, že pro řešitele je nejjednodušší analýza deterministických statických modelů, nejsložitější je řešení problémů, u nichž se vyskytují dynamické a stochastické procesy.

Mikroekonomické a makroekonomické modely

Mikroekonomické modely se týkají především podniků, individuálních trhů výrobků a služeb, spotřebitelů, domácností apod. Makroekonomické modely analyzují vývoj celého národního hospodářství. (Fábry, 2011, str. 13)

2.4 Metody Soft Computingu

Mezi pokročilé metody manažerského rozhodování řadíme teorii fuzzy logiky, neuronových sítí, genetických algoritmů, chaosu a další za použití výpočetní techniky. Využití všech výše zmíněných teorií je různorodé, dají se použít pro návrh optimalizace technologického procesu, rozhodovací úlohy s cílem dosažení optima, odhady cen nemovitostí, oceňování kvality klienta za účelem poskytnutí úvěru, optimalizace investičního rozhodování a podobně. (Dostál, 2008, str. 7)

2.4.1 Fuzzy množiny a fuzzy logika

Fuzzy množina určuje, jakou měrou prvek do dané množiny patří či nepatří. Měří tedy jistotu nebo nejistotu členství prvku v množině v rozmezí od 0 do 1. Užití míry členství odpovídá v řadě situací lépe než užití konvenčních způsobů zařazování členů do množiny podle přítomnosti či nepřítomnosti. (Dostál, 2008, str. 8)

Fuzzy logika je matematický formální rámec, který využívá teorii fuzzy množin. Fuzzy logika poskytuje matematický rámec pro reprezentaci a práci s nejistotou ve smyslu vágních pojmů, nepřesností, nedostatku informací a částečné pravdy. Systémy s fuzzy logikou jsou velmi užitečné nejen v situacích zahrnujících velmi složité systémy, ale také v situacích, kdy je zaručeno alespoň částečné řešení. (Tettamanzi a Tomassini, 2001, str. 83)

Proces tvorby modelu s fuzzy logikou probíhá v následujících etapách:

1. Fuzzifikace
2. Fuzzy inference
3. Defuzzifikace (Dostál, Rais a Sojka, 2005, str. 23)

V následujícím textu budou jednotlivé fáze popsány.

Fuzzifikace

První etapa spočívá v převedení reálných proměnných na jazykové proměnné. Definování jazykových proměnných vychází ze základní lingvistické proměnné, např. u proměnné riziko lze zvolit atributy: žádné, velmi nízké, nízké, střední, vysoké, velmi vysoké. Obvykle se využívají tři až sedm atributů základní proměnné. Stupeň členství atributů proměnné v množině se vyjadřuje matematickou funkcí. Existuje mnoho tvarů členských funkcí. Typy, které našly své uplatnění v praxi, se nazývají standardní funkce členství. Stupeň členství v množině se týká jak vstupních, tak výstupních funkcí. (Dostál, Rais a Sojka, 2005, str. 23)

Fuzzy inference

Tento krok definuje chování systému pomocí pravidel typu <Když>, <Potom>, <Nebo>, <A> na jazykové úrovni. V příslušných algoritmech se objevují podmínkové věty, vyhodnocující stav příslušné proměnné. Podmínkové věty mohou vypadat následovně:

$$\langle \text{Když} \rangle \text{Vstup}_a \langle \text{A} \rangle \text{Vstup}_b \langle \text{A} \rangle \dots \langle \text{A} \rangle \text{Vstup}_x \langle \text{Potom} \rangle \text{Výstup}_1$$

Což znamená: Když nastane stav Vstup_a a zároveň Vstup_b , ..., Vstup_x nebo Vstup_y ..., potom je situace Výstup_1 . Logickou spojku <A> lze nahradit logickým výrazem <Nebo>. (Dostál, Rais a Sojka, 2005, str. 23)

Pravidla fuzzy logiky představují expertní systém. Každá kombinace atributů proměnné, vstupujících do systému a vyskytujících se v podmínce <Když>, <Potom>, představuje jedno pravidlo. Pro každé pravidlo je třeba určit stupeň podpory, tj. váhu pravidla v systému. Výsledek systému s fuzzy logikou závisí do značné míry na správném určení významu definovaných pravidel. Váhu těchto pravidel lze v rámci průběhu optimalizace systému měnit. Podobně jako pro část pravidla umístěného

za <Když> je třeba vybrat odpovídající atribut <Potom>. Tato pravidla si tvoří uživatel sám.

Výsledkem fuzzy inference je jazyková proměnná. V případě analýzy rizika mohou mít atributy hodnotu např. velmi nízké, nízké, střední, vysoké, velmi vysoké riziko, což může vést k výstupům říkajících, zda investici provést či ne. (Dostál, Rais a Sojka, 2005, str. 24)

Defuzzifikace

Poslední etapa převádí výsledek předchozí operace fuzzy inference na reálné hodnoty. Reálnou akcí může být stanovení výše rizika. Cílem defuzzifikace je převedení fuzzy hodnoty výstupní proměnné tak, aby slovně co nejlépe reprezentovala výsledek fuzzy výpočtu.

Při postupném zadávání dat funguje systém s fuzzy logikou jako automat. Na vstupu může být mnoho proměnných. (Dostál, Rais a Sojka, 2005, str. 24)

Fuzzy logiku je možné využít v různých oblastech manažerského rozhodování, například v oblasti výrobní, investiční, řízení rizik, personální a další. Ve většině případů jde o výběr z několika variant, kdy systém s fuzzy logikou fungující jako automat ohodnotí jednotlivé varianty určitou mírou realizovatelnosti. K modelování těchto systémů se používá matematického softwaru, jako je MathWorks MATLAB či FuzzyTech.

2.4.2 Umělé neuronové sítě

Umělé neuronové sítě (Artificial Neural Networks, ANN, či jen NN) tvoří analogii lidského myšlení, zjednodušeně kopírují princip lidského mozku. Bývají popisovány jako tzv. černá skříňka, u níž není detailně známa vnitřní struktura. Na tu obvykle klademe pouze předpoklady, které umožní popsat chování systému nelineární funkcí, která provádí transformaci ze vstupu na výstup. (Dostál, 2015, str. 111)

Umělé neuronové sítě zpravidla fungují ve dvou fázích. V první fázi vystupuje síť jako nezkušený člověk, učí se nastavit své parametry tak, aby odpovídaly požadované topologii sítě. V druhé fázi již síť samostatně převádí vstupy na výstupy na základě znalostí získaných v prvním kroku. Každá neuronová síť má definované


vrstvy, a to vrstvy vstupní, několik vrstev skrytých a vrstvy výstupní, způsob výuky a proces získávání poznatků.

Neuronové sítě je vhodné použít v případech, kdy značnou roli v procesu hraje náhoda a deterministické závislosti jsou natolik složité a provázané, že je nedokážeme analyzovat a analyticky identifikovat. Používají se tedy při modelování složitých a nevratných strategických rozhodnutí, zde je vhodné využít sítě s více skrytými vrstvami. (Dostál, 2008, str. 42)

Biologický neuron

Původním záměrem při vývoji umělých neuronových sítí byla snaha pochopit a modelovat, jakým způsobem funguje lidský mozek, tedy jakým způsobem člověk myslí. Neurofyziologické poznatky pomohly vytvořit zjednodušené matematické modely, které se dají využít pro výpočty při řešení praktických úloh z umělé inteligence.

Nervová soustava člověka zprostředkovává vztahy mezi vnějším prostředím a organismem i mezi jeho částmi a zajišťuje tak reakci na vnější podněty i na vnitřní stavy organismu. Základním stavebním funkčním prvkem nervové soustavy je nervová buňka, tzv. *neuron*. Neurony jsou samostatné specializované buňky určené k přenosu, zpracování a uchování informací nutných pro realizaci životních funkcí organismu. Lidský mozek obsahuje přibližně 10^{11} neuronových buněk různého typu. Schéma struktury neuronu je uvedena na Obrázek 1. (Šíma a Neruda, 1996, str. 21 - 22)



Obrázek 1 - Biologický neuron

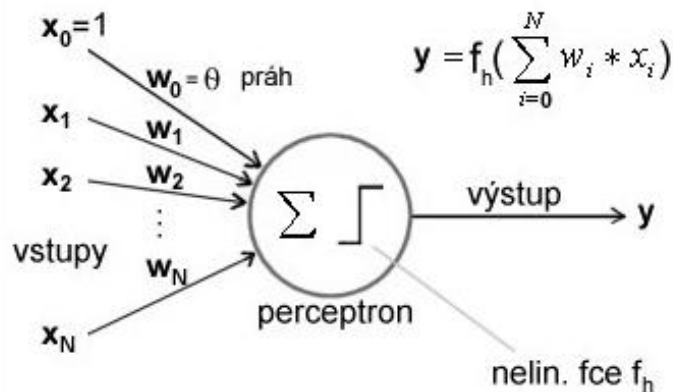
Zdroj: Institut biostatistiky a analýz Masarykovy univerzity

Neuron je přizpůsoben pro přenos signálu tak, že kromě vlastního těla neuronu, tzv. *somatu*, má i vstupní kanály, *dendrity*, a výstupní přenosový kanál, *axon*. Z axonu obvykle odbočuje řada větví, tzv. *terminálů*, zakončených blánou, která se převážně stýká s výběžky, tzv. *trny*, dendritů jiných neuronů. K přenosu informace pak slouží unikátní mezineuronové rozhraní, tzv. *synapse*. (Šíma a Neruda, 1996, str. 22) Jeden axon může tvořit až deset tisíc synaptických spojení s jinými buňkami. (Marček a kol., 2008, str. 152) Míra synaptické propustnosti je nositelem všech významných informací během celého života nejen lidského organismu. Z funkčního hlediska lze *synapse* rozlišit na tzv. *excitační*, které umožňují rozšíření vzruchu v nervové soustavě, a na tzv. *inhibiční*, které způsobují jeho útlum. (Šíma a Neruda, 1996, str. 22 - 23)

Z axonu na dendrity jiných neuronů jsou přenášeny elektrické impulsy a to synaptickými branami, které svou propustností určují intenzitu podráždění dalších neuronů. Takto podrážděné neurony při dosažení určité hraniční meze, tzv. *prahu*, samy generují impuls a zajišťují tak šíření příslušné informace. (Šíma a Neruda, 1996, str. 23)

Umělý neuron a neuronová síť


Umělý neuron je založen na principech biologického neuronu. Vstupní informace jsou váženy vahami (weights). Odečítá se prahová hodnota (threshold) a aktivační funkcí (activation function) se signál transformuje na výstupní signál, který je předán následujícím neuronům ve skryté, popřípadě výstupní vrstvě. Nejjednodušší neuronová síť je označovaná jako perceptron. (Dostál, 2015, str. 113) Na následujícím obrázku je znázorněno schéma umělého neuronu.



Obrázek 2 - Umělý neuron

Zdroj: Marček a kol., 2008, str. 155


Aktivační nebo také transformační funkce může být skoková, spojitá lineární nebo spojitá nelineární. (Kuba, 1995, str. 6) Konkrétně může jít o funkce ostré nelinearity (skoková funkce, hardlim), saturovaná lineární funkce (po částech lineární, satlin), standardní (logistická) sigmoida (logsig), hyperbolický tangens (tansig) atd. (Šíma a Neruda, 1996, str. 33 - 34, Dostál, 2015, str. 114) Průběh a matematický předpis funkcí je znázorněn na obrázku 3.



Obrázek 3 - Grafy aktivačních funkcí

Zdroj: Šíma a Neruda, 1996, str. 33 - 34

V praxi se využívá spíše neuronových sítí s více vrstvami a více neurony ve skryté vrstvě. Vícevrstevná neuronová síť je využita na následujícím obrázku.



Obrázek 4 - Schéma vícevrstevné neuronové sítě

Zdroj: Marček a kol., 2008, str. 157

Backpropagation

Při výpočtu vah neuronové sítě je u řízeného učení (tréninku) cílem optimalizačního algoritmu nalezení globálního extrému, tj. globálního minima chyby pro daný parametr úlohy. Mezi nejužívanější algoritmy učení patří např. Backpropagation, Levenberg-Marquardt, Conjugate Gradient Descent či volba vstupů pomocí genetických algoritmů. Backpropagation je metoda zpětného šíření chyby s následnou úpravou vah spojení umělých neuronů. Jde o nejužívanější metodu učení

neuronových sítí. (Dostál, 2015, str. 116) V rámci algoritmu backpropagation jde o to, aby bylo vhodnou volbou rychlosti učení dosaženo minimalizace chybové funkce sítě. (Šíma a Neruda, 1996, str. 59 – 60).

Klíčovým momentem modelu vícevrstvé neuronové sítě s učícím algoritmem backpropagation je volba vhodné topologie pro řešení konkrétního praktického problému. Zřídka jsou podrobněji známy vztahy mezi vstupy a výstupy, aby se toho dalo využít při návrhu speciální architektury. Architektura vícevrstvé sítě (tedy počet skrytých neuronů) by měla odpovídat složitosti řešeného problému. (Šíma a Neruda, 1996, str. 62)

2.4.3 Genetické algoritmy

Genetické algoritmy se používají především pro hledání řešení a optimalizaci složitých problémů z praxe. Genetické algoritmy hledají řešení simulací přirozené evoluce, tedy např. tím, že zachovávají nejvhodnější strategii.

Obecně řečeno, nejvhodnější prvky populace mají možnost se dále reprodukovat a přežít do další generace a zajistit tak zdokonalující se úspěšnou generaci. Méně kvalitní jedinci však mohou náhodou také přežít a rozmnožit se. Pro manipulaci s chromozomy (jedinci v populaci) se využívají operátory selekce, křížení a mutace. (Houck, Joines a Kay, 1995)

Genetický algoritmus se provádí v následujících krocích:

- vytvoření počáteční populace jedinců
- ocenění kvality jedinců (chromozomů) dané populace pomocí fitness funkce
- tvorba nových chromozomů pomocí operátorů selekce, křížení a mutace
- odstranění starých jedinců z původní populace
- vložení nových jedinců do populace a jejich ocenění
- ukončení procesu po splnění ukončující podmínky a nalezení nejvhodnějšího chromozomu jako řešení problému. (Dostál, 2008, str. 86)

2.5 Metody analýzy dat

V rámci dizertační práce je použito metod analýzy dat, tedy metod z oblasti statistiky, a to:

Popisná statistika

Jde o disciplínu popisující a sumarizující informace obsažené ve velkém množství dat pomocí tabulek, grafů, funkcionálních a číselných charakteristik. Činí tak pomocí základních matematických operací. Cílem popisné statistiky je zpřehlednit informace skryté v datových souborech (Budíková a kol., 2010, str. 12)

Matematická statistika

Matematická statistika je věda, která buduje metody pro analýzu dat a využívá při tom princip statistické indukce. Její součástí je teorie odhadu, testování statistických hypotéz, statistická predikce. (Budíková a kol., 2010, str. 12)

2.5.1 Regresní analýza

Metody regresní a korelační analýzy se využívají k poznání a matematickému popisu statistických závislostí. Jednostrannými závislostmi se zabývá regresní analýza, vzájemnými závislostmi pak korelační analýza. V korelační analýze se klade důraz více na intenzitu (sílu) vzájemného vztahu než na zkoumání veličin ve směru příčina – následek. (Seger, 1995, str. 168)

Regresní analýza popisuje tvar vztahu mezi dvěma proměnnými (X a Y) a charakterizuje jeho vhodnost pro predikci hodnot závisle proměnné pomocí hodnot nezávisle proměnné. Jednoduchá lineární regresní analýza spočívá v proložení dat lineární funkcí.


Při prokládání dat přímkou je snaha najít takovou přímku, která je získaným datům, tedy bodům zobrazeným v grafu co možná nejlépe. Jde o takovou přímku, která bude nejlépe predikovat y -hodnoty pomocí x -hodnot. Z toho plyne, že přímka by měla být nejlépe k bodům ve vertikálním směru, protože chyby predikce se týkají y -hodnot.

Rozdílu mezi naměřenou a predikovanou hodnotou říkáme *reziduální hodnota predikce* (e) nebo chyba predikce. Dobře proložená přímka $y = ax + b$ minimalizuje velikosti reziduálních hodnot pro hodnoty $\{(x_i; y_i)\}$, kterými přímku prokládáme. Nejčastěji používaná metoda je *metoda nejmenších čtverců*. (Hendl, 2012, str. 279)

Hodnoty a a b přímky $y = ax + b$ získáme metodou nejmenších čtverců tak, aby byl minimální součet druhých mocnin reziduálních hodnot:

$$s_r^2 = \sum e_i^2 = \sum (y_i - a - bx_i)^2 \quad (1)$$

vzhledem k parametrům a , b . Grafická interpretace odchylek od regresní přímky pro metodu nejmenších čtverců je znázorněna na Obrázek 5.



Obrázek 5 - Znázornění metody nejmenších čtverců

Zdroj: Hendl, 2012, str. 279

Jde o minimalizaci čtverce úseček, které vyznačují vzdálenost bodu od proložené přímky ve směru osy y . Výpočet minima vede k optimálním hodnotám.

$$b = r \frac{s_y}{s_x}, a = \bar{y} - b\bar{x}, \quad (2)$$

kde r je korelace obou proměnných a s_x , s_y jsou směrodatné odchylky naměřených hodnot proměnných X a Y . Nalezená přímka je nazývána regresní přímka. Hodnota \hat{y}_i je odhad cílové proměnné pomocí regresního vztahu ($\hat{y}_i = a + bx_i$).

$$\text{reziduální hodnota} = \text{naměřená hodnota } y - \text{predikovaná hodnota } \hat{y}_i. \quad (3)$$

(Hendl, 2012, str. 279 - 280)

V práci je dále využit koeficient determinace, který udává v procentech tu část celkové variability proměnné Y , resp. X , která je vysvětlena znalostí hodnoty nezávisle proměnné X , resp. Y . Koeficient determinace je poměr vysvětlené variability k celkové variabilitě proměnné Y :

$$\text{koeficient determinace } r^2 = \frac{\text{variabilita vysvětlená modelem}}{\text{celková variabilita}} = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}. \quad (4)$$

(Hendl, 2012, str. 279 - 280)

Chybu předpovědi lze stanovit pomocí chybových metrik nebo také míry přesnosti:

- střední chyba odhadu (Mean Error, ME), $ME = \frac{\sum(y_i - \hat{y}_i)}{n}$,
- střední kvadratická chyba (Mean Squared Error, MSE), $MSE = \frac{\sum(y_i - \hat{y}_i)^2}{n}$,
- střední absolutní chyba (Mean Absolute Error, MAE), $MAE = \frac{\sum|y_i - \hat{y}_i|}{n}$.

Chyby bývají často využívány v analýze časových řad pro stanovení přesnosti vyrovnání trendovou funkcí. Nejčastěji používaná je MSE, střední čtvercová chyba. (Seger, 1995, str. 293)

2.5.2 Korelační analýza

Korelační analýza se používá k posouzení kvality regresní funkce a zjištění intenzity (síly, těsnosti) závislosti. Cílem výzkumu bývá i určení síly vztahu mezi dvěma náhodnými veličinami, o kterých nelze s určitostí říci, která je závislá a která je nezávislá. (Hudec, 2007, str. 38)

Koeficient korelace

Pokud je závislost mezi dvěma proměnnými X a Y lineární, lze tuto závislost kvantitativně vyjádřit pomocí korelačního koeficientu r :

$$r = \frac{S_{XY}}{\sqrt{S_X^2 S_Y^2}}, \quad (5)$$

kde: $S_{XY} = \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$, $S_X^2 = \sum_{i=1}^n (X_i - \bar{X})^2$ a $S_Y^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2$.

Koeficient korelace může nabývat záporných hodnot, jeho definiční obor je od -1 do +1. Jestliže je koeficient korelace roven 1, existuje mezi proměnnými přímá lineární závislost. Obdobně koeficient korelace -1 znamená, že mezi proměnnými je nepřímá funkční lineární závislost. Hodnota koeficientu 0 značí lineární nezávislost, neboli nekorelovanost, proměnných. Čím více se tedy blíží koeficient korelace v absolutní hodnotě jedné, tím považujeme danou lineární závislost za silnější; čím více se blíží nule, tím ji považujeme za volnější. (Hindls, 2007, str. 206)

Korelační matice

Často dochází k potřebě zjištění stupně závislosti mezi více proměnnými. Charakteristiky polohy a variability vícerozměrné náhodné veličiny nejsou na rozdíl od jednorozměrné náhodné veličiny jednoduchá čísla, ale vektory a matice.

Uvažujme n -rozměrnou náhodnou veličinu (náhodný vektor) (X_1, \dots, X_n) . Potom těsnost závislosti jednotlivých složek vektoru charakterizuje matice – korelační matice.

Korelační matice se skládá z vypočítaných hodnot koeficientů korelace mezi všemi možnými dvojicemi proměnných. V prvním řádku jsou hodnoty koeficientů korelace první proměnné s hodnotami ostatních proměnných atd. Na diagonále korelační matice jsou jedničky, protože platí, že koeficient korelace mezi hodnotami stejné proměnné se rovná 1. Symbolicky lze korelační matici zapsat následovně:

$$K = \begin{pmatrix} 1 & \rho_{12} & \cdots & \rho_{1n} \\ \rho_{21} & 1 & \cdots & \rho_{2n} \\ \rho_{31} & \rho_{32} & \cdots & \rho_{3n} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n1} & \rho_{n2} & \cdots & 1 \end{pmatrix}, \quad (6)$$

kde $\rho_{ij} = \rho(X_i, X_j)$ je korelační koeficient náhodných veličin X_i a X_j , pro $i, j = 1, \dots, n$. (Hudec, 2007, str. 42)

2.5.3 Analýza časových řad

Časová řada je posloupnost věcně a prostorově srovnatelných pozorování (dat), která jsou jednoznačně uspořádána z hlediska času. Časové řady dle rozhodného časového hlediska rozlišujeme na intervalové a okamžikové.

V dizertační práci bude analyzována časová řada intervalová, u které velikost ukazatele závisí na délce intervalu, za který je sledován. Z povahy intervalových ukazatelů vyplývá, že se s ohledem na možné zkreslení srovnání mají vztahovat ke stejně dlouhým intervalům. Často nelze srovnávat přímo časové řady ani pro stejně dlouhé měsíce, neboť se mohou lišit například po stránce pracovních dní. Aby bylo možné zajistit srovnatelnost, je nutné přepočítat všechna období na jednotkový časový interval. Tato operace se nazývá očišťování časových řad od důsledků kalendářních variací.

Údaje očištěné na pracovní dny lze vypočítat následovně:

$$y_t^{(0)} = y_t \frac{\bar{p}_t}{p_t}, \quad (7)$$

kde p_t – počet pracovních dní v příslušném dílčím období,

\bar{p}_t – průměrný počet dní ve stejném období. (Seger, 1995, str. 257 - 259)

2.5.4 Přístupy k modelování časových řad

Klasický (formální) model

Model vychází z dekompozice řady na čtyři složky, a to na složku trendovou (T_t), sezónní (S_t), cyklickou (C_t) a náhodnou (ε_t).

- *Trendem* rozumíme dlouhodobou tendenci v chování pozorovaného ukazatele. V průběhu sledovaného období můžeme sledovat dlouhodobý růst, dlouhodobý pokles nebo mohou hodnoty kolísat kolem určité hodnoty.
- *Sezónní složka* je pravidelně se opakující odchylka od trendové složky, vyskytující se u časových řad údajů s periodicitou kratší než jeden rok. Ke kolísání může dojít v důsledku změn jednotlivých ročních období nebo též vlivem různých společenských zvyklostí.
- *Cyklická složka* představuje kolísání okolo trendu s periodou delší než jeden rok. Někdy nebývá cyklická složka považována za samostatnou složku, ale bývá součástí trendu.
- *Náhodná (reziduální) složka* je taková, kterou nelze popsat žádnou funkcí času. Je to složka, která zbývá po vyloučení trendu, sezónní a cyklické složky. Často jde o náhodnou (stochastickou) složku, jejíž chování lze popsat pravděpodobnostně. (Seger, 1995, str. 267)

Vlastní tvar rozkladu může být dvojího typu:

- *Aditivní dekompozice* – jednotlivé složky jsou uvažovány ve skutečných absolutních hodnotách a jdou měřeny v jednotkách y_t :

$$y_t = T_t + S_t + C_t + \varepsilon_t. \quad (8)$$

- *Multiplikativní dekompozice* – většinou je pouze trendová složka uvažována ve své absolutní hodnotě a ostatní složky jsou uvažovány v relativních

hodnotách vůči trendu. Tento způsob dekompozice se používá v případě, že variabilita časové řady roste nebo se mění v čase.

$$y_t = T_t * S_t * C_t * \varepsilon_t. \quad (9)$$

Multiplikativní model lze převést na aditivní logaritmickou transformací. Jde o postup, kdy jsou obě strany rovnice logaritmovány přirozeným logaritmem:

$$\ln(y_t) = \ln(T_t) + \ln(S_t) + \ln(C_t) + \ln(\varepsilon_t). \quad (10)$$

(Seger, 1995, str. 266 - 267)

Box-Jenkisonova metodologie

Za základní prvek konstrukce modelu časové řady považuje náhodnou složkou, jež může být tvořena korelovanými náhodnými veličinami. Mezi modely, které tato metodologie používá, patří model klouzavých součtů MA, autoregresní model AR, smíšený model ARMA, speciálně také integrovaný model ARIMA a sezónní model SARIMA. (Seger, 1995, str. 267 - 268)

Box-Jenkinsonově metodologii je věnována podkapitola 2.5.7.

Spektrální analýza

Časová řada je považována za směs sinusových a kosinusových křivek s různými amplitudami a frekvencemi. Využitím speciálních statistických nástrojů, jako je periodogram a spektrální hustota, lze při spektrální analýze získat představu o zastoupení jednotlivých frekvencí v časové řadě, to umožňuje určit frekvence, které jsou v dané časové řadě zastoupeny nejvýrazněji, a explicitně odhadnout jim odpovídající koeficienty periodických složek. (Seger, 1995, str. 268)

2.5.5 Klouzavé průměry

Podstata vyrovnaní pomocí klouzavých průměrů spočívá v tom, že posloupnost empirických pozorování je nahrazena řadou průměrů vypočítaných z těchto pozorování. Vyhlazenou hodnotu časové řady v okamžiku t je možné získat určitým zprůměrováním původních pozorování z jistého okolí pozorování y_t . Pro vysvětlení podstaty klouzavých průměrů bývá využit termín „okénka“, které klouže podél časové řady a v jehož rámci se průměruje. (Budíková a kol., 2010, str. 264)

Mezi klouzavé průměry patří:

- prosté klouzavé průměry,

- vážené klouzavé průměry,
- centrované klouzavé průměry.

Prostý klouzavý průměr

Vyhlazovací okénko zahrnuje d členů nalevo od bodu t a d členů napravo od bodu t . Šířka vyhlazovacího okénka je pak liché číslo a má šířku $h = 2d + 1$. Je využit prostý klouzavý průměr. Prvních a posledních d hodnot se vyhlazování netýká, jelikož zde není okénko symetrické. Vyhlazená hodnota ve středu vyhlazovacího okénka je dána vztahem:

$$\hat{y}_t = \frac{1}{2d+1} (y_{t-d} + y_{t-d+1} + \dots + y_{t+d}) = \frac{1}{2d+1} \sum_{k=0}^{2d} y_{t-d+k}, \quad (11)$$

$$t = d + 1, \dots, n - d.$$

(Budíková a kol., 2010, str. 264)

Centrovaný klouzavý průměr

Centrovaný klouzavý průměr se využívá v případě, že šířka vyhlazovacího okénka je sudé číslo, tedy $h = 2d$. Klouzavý průměr se pak vypočítá jako průměr dvou sousedních jednoduchých klouzavých průměrů.

$$\hat{y}_t = \frac{1}{2} \left(\frac{y_{t-d} + y_{t-d+1} + \dots + y_{t+d-1}}{2d} + \frac{y_{t-d+1} + y_{t-d+2} + \dots + y_{t+d}}{2d} \right),$$

$$\hat{y}_t = \frac{1}{4d} \left(\sum_{i=0}^{2d-1} y_{t+i-d} + \sum_{i=1}^{2d} y_{t+i-d} \right), \quad (12)$$

$$t = d + 1, \dots, n - d.$$

(Budíková a kol., 2010, str. 264)

Pro stanovení sezónních indexů byl v práci použit výpočet centrovaných klouzavých průměrů.

2.5.6 Sezónní očištění

Při analýze časových řad s periodicitou kratší než jeden rok se setkáváme téměř vždy s existencí sezónních vlivů reprezentovaných v modelu časové řady sezónní složkou. Sezónními vlivy rozumíme soubor přímých či nepřímých příčin, které se rok co rok pravidelně opakují. Protože periodické kolísání do jisté míry zakrývá dynamiku ekonomických jevů, provádí se tzv. sezónní očišťování, jehož úkolem je vyloučit sezónní složku z analyzované řady. Úkolem popisu složky je tedy jednak kvantifikace

sezónní složky za účelem analýzy sezónnosti, jednak výpočet sezónně očištěné časové řady. (Seger, 1995, str. 310-311)

Obecně lze úlohu sezónního očištění formulovat tak, že jde o modelové rozdělení časové řady na složku trendovou, sezónní a náhodnou, přičemž prvořadým úkolem je zbavit časovou řadu sezónní složky, ale přitom ponechat v modelu složku trendovou, popř. cyklickou (vyskytuje-li se). (Seger, 1995, str. 333-334)

2.5.7 Box-Jenkinsonova metodologie

Dekompoziční metody analýzy časových řad kladou důraz především na práci se systematickými složkami časové řady (tj. s trendovou, sezónní a cyklickou složkou) a jednotlivá pozorování se berou jako nekorelovaná. Box-Jenkinsonova metodologie naproti tomu bere za základní prvek konstrukce modelu časové řady reziduální složku, která může být tvořena korelovanými (závislými) náhodnými veličinami. Box-Jenkinsonova metodologie tedy vychází z vyšetřování závislostí v časové řadě neboli v tzv. korelační analýze. Základní principy této metodologie zformulovali Box a Jenkins. (Box a Jenkins, 1976)

Modely, s nimiž Box-Jenkinsonova metodologie pracuje, jsou:

Modely stacionárních časových řad

Základním prostředkem podávajícím informaci o charakteru stochastického procesu je autokorelační funkce a parciální autokorelační funkce. Modely stacionárních časových řas jsou charakteristické specifickou formou autokorelační funkce a parciální autokorelační funkce, takže jejich odhady lze použít při identifikaci modelu konkrétních analyzovaných časových řad. (Arlt a Arltová, 2007, str. 26)

1. Autoregresní model (AR, Autoregressive model).
2. Model klouzavých průměrů (MA, Moving Average) – jde o jeden z nejjednodušších modelů. Model klouzavých průměrů prvního řádu je vhodný pro časovou řadu, v níž jsou všechny pozorování navzájem nekorelovaná až na bezprostředně sousední dvojice.
3. Smíšené modely ARMA. (Cipra, 1986, str. 19)

Modely nestacionárních časových řad

V ekonomické praxi se lze velmi často setkat s časovými řadami tvořenými nestacionárními stochastickými procesy. Tyto časové řady jsou charakteristické přítomností trendu. (Arlt a Arltová, 2007, str. 38)

1. Modely náhodné procházky (Random Walk Proces).
2. Integrované modely ARIMA – je možné je použít k modelování integrovaných procesů, tedy nestacionárních procesů, které lze diferenciací určitého řádu převést na stacionární proces. (Kvasnička a Vašíček, 2001)

Modely sezónních časových řad

Důležitou vlastností mnoha krátkodobých ekonomických časových řad je sezónnost. Tradičním předpokladem je, že sezónní složka časové řady má pravidelný deterministický charakter. V případě ekonomických a finančních časových řad je však často nutno předpokládat, že sezónní složka má stochastický charakter. (Arlt a Arltová, 2007, str. 42)

1. Sezónní autoregresní procesy SAR.
2. Sezónní procesy klouzavých průměrů SMA.
3. Smíšené sezónní a nesezónní procesy SARMA.
4. Modely sezónních integrovaných časových řad SARIMA – obsahující sezónní integrovaný proces. (Arlt a Arltová, 2007, str. 42 - 46)

Box-Jenkinsonova metodologie je východiskem pro modelování takových nestacionárních časových řad a sezónních časových řad, které vykazují složitou stochastickou strukturu. Modely vycházející z této metodologie jsou často flexibilnější než dekompoziční modely, což znamená, že model je schopen se rychle adaptovat na změněný charakter časové řady. Jedná se o stochastické modely, které mohou stochasticky modelovat trend i sezónnost. Díky tomu lze popisovat i takové časové řady, u kterých modely klasické analýzy selhávají. (Cipra, 1986, str. 100)

Analýza časové řady se v rámci této metodologie provádí systematicky podle předem daného klíče. Postup je možné rozdělit do tří základních kroků – identifikace, odhad parametrů a ověřování modelu. (Cipra, 1986, str. 100)

Je potřeba však také uvést nevýhody Box-Jenkinsonovy metodologie:

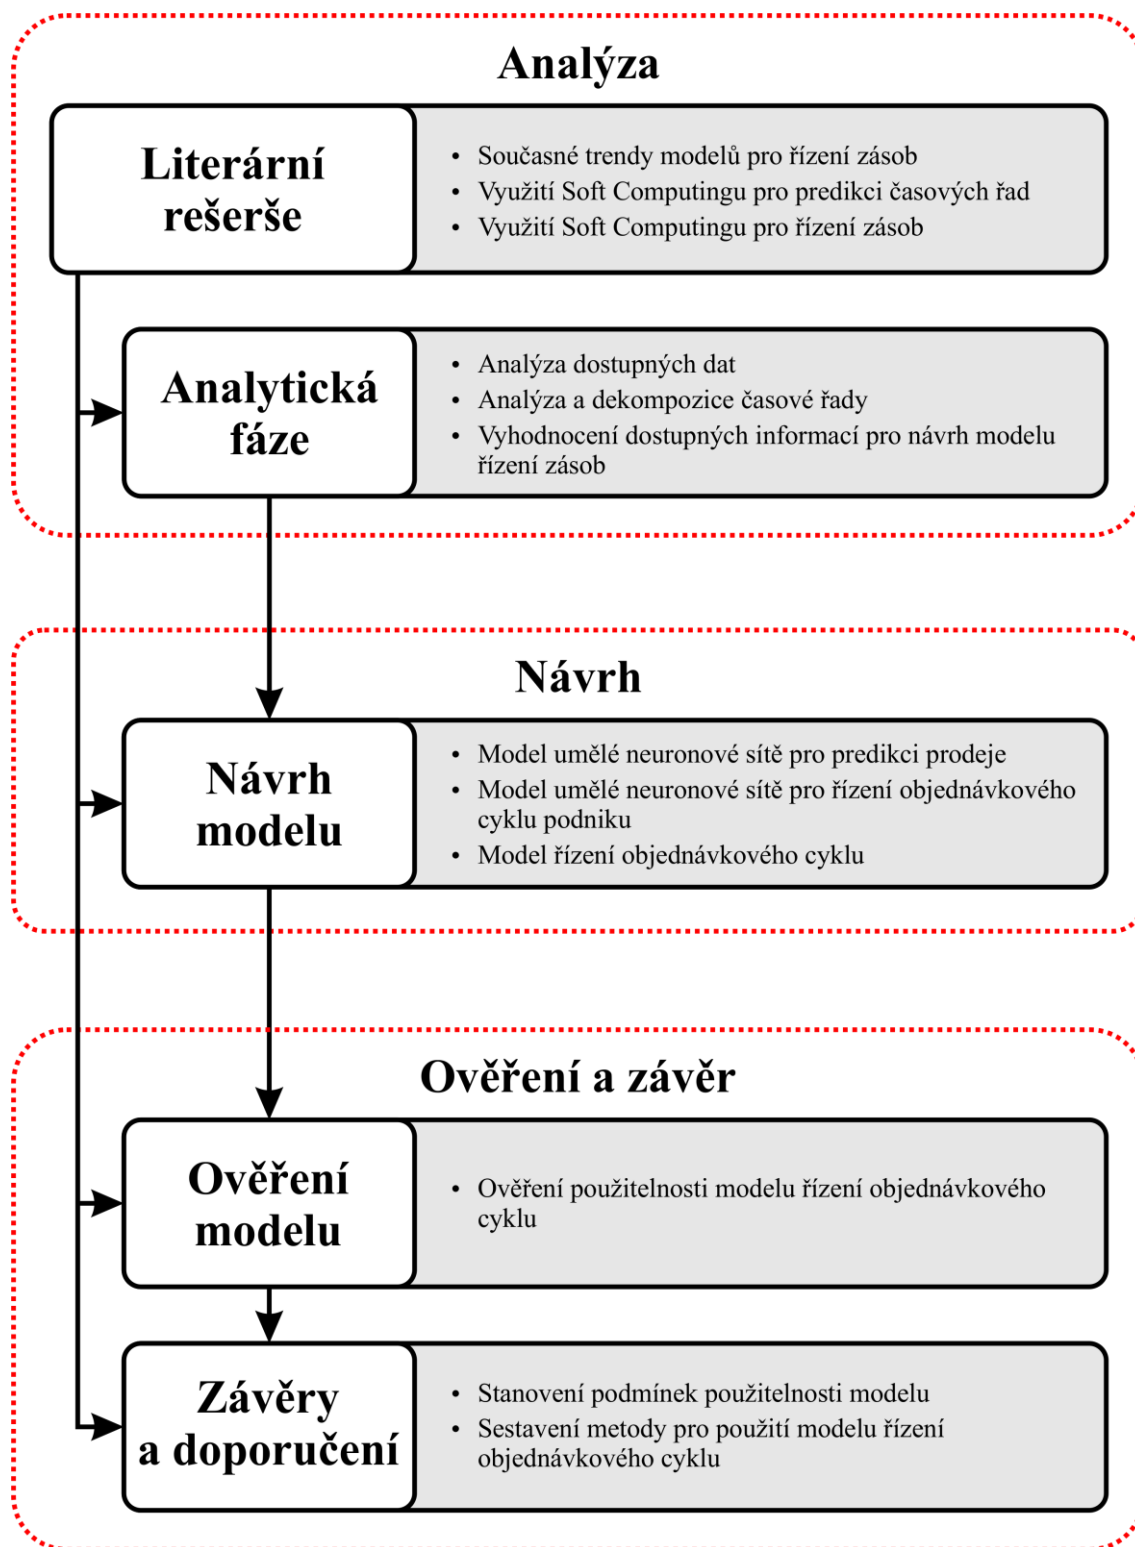
- Pro vybudování spolehlivého modelu lze analyzovat pouze dostatečně dlouhé časové řady o délce alespoň 50 pozorování. Je tedy vhodný pro řady s krátkými časovými intervaly mezi jednotlivými pozorováními.
- Poměrně složitá interpretace výsledků modelů. (Cipra, 1986, str. 100-101)

2.6 Postup řešení dizertační práce

Dizertační práce je zpracována na základě tří hlavních okruhů, skládá se z pěti dílčích kroků. Obecně lze říci, že se zpracování dizertační práce skládá z částí analytické, návrhové a části pro ověření a tvorby závěrů.

Sekundární výzkum je zaměřen na provedení literární rešerše a analýzu obsahu dostupných zdrojů vztahující se ke zkoumané problematice. Sumarizace poznatků ohledně aktuálního stavu řešené problematiky ve vědecké oblasti vedla k odhalení výzkumné mezery, na základě které byly zpracovány výsledky dizertační práce.

Ke znázornění kroků, které vedly ke zpracování dizertační práce, slouží následující obrázek (Obrázek 6).



Obrázek 6 - Postup zpracování dizertační práce

Zdroj: Vlastní zpracování

3 Zhodnocení současného stavu řešené problematiky

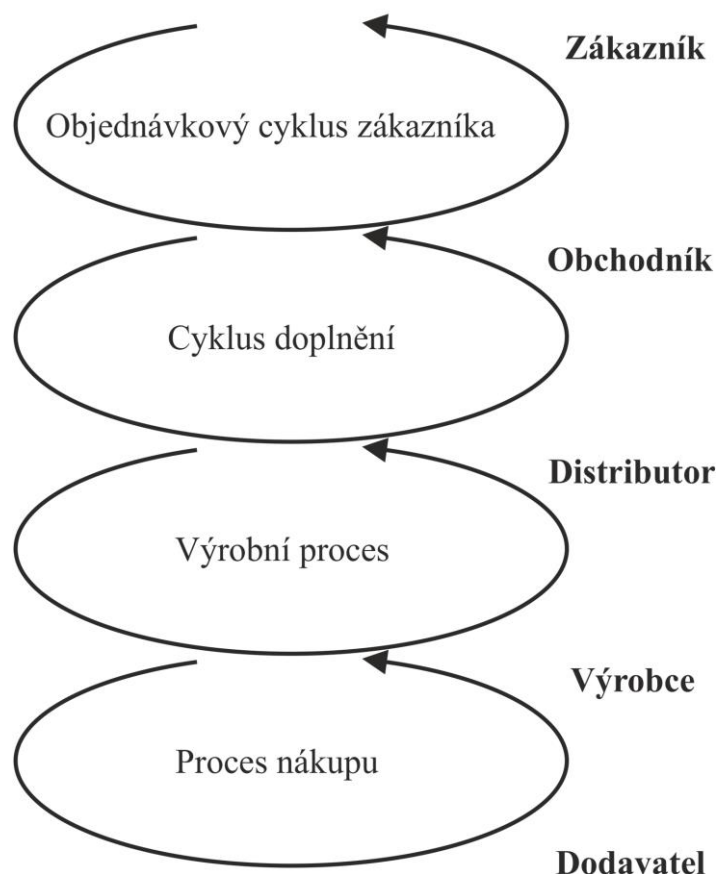
3.1 Řízení dodavatelského řetězce

Řízení dodavatelského řetězce (SCM - Supply Chain Management) je jednou ze strategií moderního managementu pro optimalizaci všech činností a systémů pro zabezpečení dodávky produktů a služeb od dodavatelů surovin přes jejich výrobu nebo vývoj, přes distribuční kanály až ke koncovému spotřebiteli. (Križko, 2002)

Předmětem SCM je dodavatelský řetězec, jenž představuje síť organizací, které jsou zapojeny do různých procesů a činností vytvářející hodnotu ve formě výrobků a služeb do rukou konečnému spotřebiteli. (Stadtler a Kilger, 2005, str. 9) Dodavatelský řetězec se skládá ze všech účastníků, kteří jsou přímo nebo nepřímo zapojeni do plnění zákaznického požadavku. V širším smyslu znamená dodavatelský řetězec dvě a více právně samostatných firem propojených materiálovým, informačním a finančním tokem. Dodavatelský řetězec nezahrnuje pouze výrobce a dodavatele, ale také přepravce, sklady, obchodníky i samotné zákazníky. (Chopra a Meindl, 2007, str. 3)

3.1.1 Procesní pohled na dodavatelský řetězec

Dodatelský řetězec je sled procesů a toků, které probíhají uvnitř a mezi různými etapami a spojují se, aby splnily požadavky zákazníka. Proces dodavatelského řetězce je rozdělen do několika sérií cyklů, každý z nich slouží jako rozhraní mezi dvěma částmi dodavatelského řetězce. (Chopra a Meindl, 2007, str. 10)



Obrázek 7 - Procesní cykly dodavatelského řetězce


Zdroj: Vlastní zpracování dle Chopra a Meindl, 2007, str. 10.

Na Obrázek 7 je znázorněno pět účastníků dodavatelského řetězce, kteří se účastní čtyř zobrazených cyklů dodavatelského řetězce.

Každý cyklus se skládá ze šesti subprocesů, které jsou znázorněny na Obrázek 8. Každý cyklus začíná nabídkou produktu dodavatelem zákazníkovi. Kupující pak zadá objednávku, která je přijata dodavatelem. Prodejce dodá objednávku, ta je přijata kupujícím. Odběratel pak může vrátit některý z produktů nebo jiný recyklovatelný materiál dodavateli nebo třetí straně. Cyklus aktivit poté začíná nanovo. (Chopra a Meindl, 2007, str. 10)

Cílem kupujícího je zajistit dostupnost produktu pro výrobu nebo zákazníky a dosáhnout úspor z rozsahu při objednávání uvnitř každého cyklu. Dodavatel se pokouší předpovědět objednávky zákazníka a snížit náklady na přijetí objednávky. Prodejce pak pracuje na včasném a správném splnění objednávky a na zlepšení výkonnosti a přesnosti procesu plnění objednávky. Kupující se snaží o minimalizaci

nákladů vyplývajících z přijímání objednávky. Zpětné toky jsou řízeny za účelem snižování nákladů a splnění cílů ochrany životního prostředí. (Chopra a Meindl, 2007, str. 10)



Obrázek 8 - Subprocesy jednotlivých procesů v dodavatelském řetězci

Zdroj: Vlastní zpracování dle Chopra a Meindl, 2007, str. 11.

I když má každý cyklus stejné základní subprocessy, můžeme mezi jednotlivými cykly najít pár důležitých rozdílů. V objednávkovém cyklu zákazníka je poptávka vzhledem k dodavatelskému řetězci externí, tudíž je nejistá. Zadání objednávky je nejisté také v ostatních cyklech dodavatelského řetězce, ale může být plánována na základě zásad, které jsou uplatňovány v jednotlivých etapách dodavatelského řetězce.

Druhým rozdílem napříč cykly je velikost objednávky. Zatímco koncoví zákazníci kupují malé množství produktů, dodavatelé musí obchodníkovi dodávat mnohem větší množství. Ve směru od koncového zákazníka k dodavateli sledujeme pravidlo, že se počet objednávek snižuje, zatímco velikost objednávek narůstá. Sdílení informací a provozních postupů je tím důležitější, čím dál se přesouváme v dodavatelském řetězci od koncového zákazníka. (Chopra a Meindl, 2007, str. 12)

3.1.2 Makro procesy dodavatelského řetězce

Procesy dodavatelského řetězce mohou být rozděleny do následujících tří makro procesů:

- *Řízení vztahů se zákazníky* (Customer Relationship Management, CRM) – procesy, které se zaměřují na styk podniku se zákazníky. Patří zde například marketing, stanovení ceny, prodej, řízení přijatých objednávek či call centra.
- *Vnitřní řízení dodavatelského řetězce* (Internal Supply Chain Management, ISCM) – jde o procesy uvnitř podniku jako je například plánování prodeje, skladovací kapacity, příprava nabídkových a poptávkových plánů a vyřizování aktuálních objednávek.
- *Řízení vztahů s dodavateli* (Supplier Relationship Management, SRM) – procesy, které se zaměřují na styk firmy s jejími dodavateli. Jde především o ohodnocení a výběr dodavatelů, vyjednávání dodavatelských podmínek, komunikace týkající se nových produktů a zadávání objednávek dodavatelům.

Pro celkový úspěch dodavatelského řetězce je velmi důležité správné propojení jednotlivých makro procesů. (Chopra a Meindl, 2007, str. 15)

Z pohledu makro procesů dodavatelského řetězce je dizertační práce zaměřena na vnitřní řízení dodavatelského řetězce a to konkrétně na plánování prodeje a plánování nákupních objednávek. Samozřejmě se předpokládá propojení správné propojení na ostatní makro procesy a zároveň správné sestavení dodavatelského řetězce.

3.1.3 Vývojové typy dodavatelského řetězce

Uspořádání dodavatelského řetězce a způsob jeho řízení může mít různé podoby. V zásadě je možné rozlišit tři odlišné typy řetězců, jež zároveň představují tři různá pokročilá pojetí.

Řetězce s přetržitými toky

Tradiční typ řetězce s přetržitými toky, kdy materiálové toky v tomto řetězci fungují na bázi *push principu* (tlačný princip). Na podkladě vyhodnocování prodeje jsou sestavovány predikce prodeje a podle nich jsou uzavírány kontrakty s dodavateli. Dodávky surovin jsou uskutečňovány pokud možno ve velkých dávkách tak, aby podnik získal očekávané výhody z kolísání cen, z množstevních rabatů a z hromadné

dopravy velkokapacitními dopravními prostředky. Dodané suroviny či zboží podnik skladuje. Dojde-li ke změně poptávky zákazníků oproti předpokladu, je situace řešena přiojednáním. Na základě push principu odesílá předcházející článek odebírajícímu článku dávku, kterou v rámci kontraktu připravil v množství a v čase vyhovujícím odesílajícímu článku. Důsledkem jsou nadměrné zásoby a přerušování toku prakticky ve všech článcích řetězce. Procesy v tomto řetězci jsou řízeny na základě plánů a predikcí, což se nemusí shodovat v okamžiku realizace procesu se skutečnou potřebou trhu. Tento typ řetězce je charakteristický mimo jiné dlouhou celkovou průběžnou dobou výrobku, kdy až 95 % z této doby připadá na neúčelné skladování a prostoje v řetězci. (Pernica, 2005, str. 233 – 234)

Řetězce s kontinuálními toky

Je zde zjednodušená struktura, kde chybí sklad surovin mezi dodavateli a výrobou a sklad hotových výrobků je redukován pouze na článek vyrovnávající tok výrobků k zákazníkovi. Tyto změny jsou možné díky využití technologie dodávek surovin Just in Time (JIT), tedy na termínované dodávky umožňující pružnější distribuci. Uplatňuje se zde *pull princip* (tažný princip), kdy předcházející článek odesílá dávku odebírajícímu článku až v okamžiku a v množství, v jakém odebírající článek potřebuje. Frekvence toku se zrychluje, články si předávají menší dávky, tok je plynulý, zásoby se zmenšují, skladové kapacity se redukují, v ideálním případě není zásob vůbec potřeba. Snižuje se tak průběžná doba setrvání výrobku v řetězci. (Pernica, 2005, str. 234 – 235)

Řetězce se synchronními toky

Jde o ideální cílový typ řetězce, je složen pouze z výroby s kompletací a konsolidací, ze zákazníků a dodavatelů. Tok materiálu je zcela plynulý, bez přerušování a bez zásob (vyjma pojistné zásoby) a je vyvážený. Uplatňuje se taktéž pull princip fungující dle konceptu tzv. „pipeline“, kde se uvnitř kteréhokoliv článku a na cestě mezi články nachází jen takové množství hotových výrobků či surovin, které je k danému okamžiku požadováno. Je proto nutné využití paralelního toku informací současně s uplatněním nových systémů jako automatická identifikace, elektronická výměna dat či technické vybavení určené k simulacím očekávaných situací. (Pernica, 2005, str. 235 – 236)

3.2 Zásobování a náklady

Nákup a produkce ve velkých dávkách umožňuje firmě zapojené do dodavatelského řetězce využít úspory z rozsahu a tím snížit náklady. Proto se využívá řízení zásobovacího cyklu. (Chopra a Meindl, 2007, str. 261)

Zásobovací cyklus je provozován tak, aby bylo možné využít úspor z rozsahu a tím snížit náklady v rámci dodavatelského řetězce. Pro správné vystižení způsobu dosahování úspor z rozsahu je nutné identifikovat jednotlivé náklady v dodavatelském řetězci, ovlivňované velikostí dodávky. (Chopra a Meindl, 2007, str. 263)

- *Průměrná jednotková nákupní cena* je klíčovou položkou při rozhodování o velikosti dodávky. Obchodník obvykle zvyšuje velikost dodávky, aby dosáhl nižší nákupní ceny na jednotku.
- *Fixní náklady na objednávku* obsahují všechny náklady, které sice nesouvisí s velikostí objednávky, ale vznikají při každém objednání. Můžou zde patřit například administrativní náklady, přepravní náklady či mzdové náklady na přijetí objednávky. Větší objednávkou je pak dosaženo snížení objednacích nákladů na jednotku.
- *Skladovací náklady* jsou náklady na držení jednotky ve skladu na určitou jednotku času, obvykle jeden rok. Jde o kombinaci nákladů kapitálu, nákladů na fyzické skladování a nákladů, které plynou ze zastarávání výrobku. Celkové skladovací náklady rostou se zvyšováním velikosti dodávky. (Chopra a Meindl, 2007, str. 263)

3.3 Řízení zásob v obchodě

Každý podnik drží nějaké zásoby na skladě. Skladové zásoby mohou být na obtíž, nutností nebo také výhodou. Obchodníci vidí sklad jako centrum jejich obchodní činnosti – co nakoupí, to prodají a preferují prodej ze skladu před dodávkami, které mají teprve dorazit.

U obchodních firem tvoří zásoby 60-80 % celkové hodnoty aktivity (tedy mnohem více než u výrobních podniků), z toho plyne, že zároveň váží 60-80 % investovaného kapitálu. Cílem řízení zásob je zajistit plynulost obchodního provozu při

minimálních nákladech s procesem zásobování souvisejících. (Mulačová, 2013, str. 377)

Důvody pro držení skladu:

- Výhoda mít zboží k dispozici kdykoliv v případě potřeby, aniž by bylo nutné speciální opatření.
- Snížení nákladů díky nákupu optimálního množství.
- Ochrana proti vlivům prognostické chyby, nepřesných záznamů nebo omylů v plánování.
- Rezerva pro případ kolísání prodeje či výroby.

Držení zásob na skladě je drahé a je tolerováno, že mnoho organizací má příliš mnoho zásob na skladě. Optimalizace skladových zásob je velmi důležité téma, je potřeba dosáhnout rovnováhy. Příliš mnoho zásob vede ke zpoždění produkce organizace, nekvalitnímu servisu či neschopnosti reagovat na nové požadavky. Ale také váže příliš mnoho prostředků, což ve firmě vede ke zhoršení schopnosti investovat. (Baily, 2003, str 136-138)

Pohyb zásob lze sledovat ve dvou oblastech. První z nich je tok zboží mezi výrobcem a obchodní jednotkou a to buď přímo, nebo prostřednictvím určitého počtu mezičlánků. Procesem distribuce produktů na uvedené ose se zabývá obchodní logistika, jež stojí na pomezí ekonomických a technických disciplín. Druhou oblastí je pak řízení pohybu zboží v obchodní jednotce. (Mulačová, 2013, str. 377)

Obchodní logistika je disciplína, zabývající se tokem zásob od výrobce až ke konečnému zákazníkovi. Zahrnuje nákup, skladování, dopravu a prodej v příslušném počtu stupňů. Soubor všech prvků podílejících se na tomto pohybu nazýváme distribučním řetězcem. (Mulačová, 2013, str. 377) V dizertační práci bude věnována pozornost jedné části obchodní logistiky a to nákupu.

3.4 Modely řízení cyklu zásob

Úkolem řízení zásob je určit optimální úroveň zásob z hlediska provozu a nejlepší režim zásobování, nejčastěji s ohledem na výši nákladů. Přístup k řízení zásob se u jednotlivých typů obchodních jednotek výrazně liší, proto také existuje více modelů řízení zásob. (Mulačová, 2013, str. 383) Zatím nebyl vyvinut univerzální model pro řízení zásob a v každé konkrétní situaci je nutné najít specifické řešení konkrétního modelu zásob na základě již existujících modelů.

Modely řízení zásob nezkoumají pohyb jednotlivých kusů zásob, ten je z pohledu managementu nepodstatný. Důraz je kladen na sledování vývoje množství zásob v obchodní jednotce v čase, tedy na zkoumání hladin zásob.

3.4.1 Klasifikace zásob

Je možné definovat pět podtříd zásob podle specifčnosti funkce, kterou plní, nebo důvodů, ze kterých vznikly. Jsou to:

- *Obratová zásoba* – vzniká ze skutečnosti, že je ekonomičtější zboží objednávat a expedovat v dávce.
- *Pojistná zásoba* – účelem je zachycovat výkyvy v poptávce během dodací lhůty objednaného prvku i kolísání v dodací lhůtě. Je to přídatná zásoba, která se udržuje vedle obratové zásoby.
- *Zásoba pro předzásobení* – vytváří se k vyrovnání předvídatelných výkyvů v přísunu a odsunu. Tyto výkyvy může představovat kolísání v důsledku uzavření firmy v době dovolených, podpora prodeje, sezónní jevy apod. Ve vlastním výzkumu nebude zásoba pro předzásobení brána v potaz, což plyne z podmínek konkrétní společnosti.
- *Vyrovňovací zásoba* – slouží k zachycení malých nepředvídatelných výkyvů.
- *Zásoba v logistickém kanále* – jde o zboží, které již má své určení, ale dosud nebylo vyexpedováno, resp. dosud nedošlo na místo určení. V této souvislosti je možné ještě dále rozlišit dopravní zásobu.
- *Dopravní zásoba* – jde o zboží, které je na cestě z jednoho místa do druhého. (Jurová, 2013, str. 88-90)

Pro potřeby managementu zásob se sledují některé důležité řídicí hladiny zásob:

- *maximální zásoba* – maximální úroveň zásob, je jí dosaženo v okamžiku dodávky zboží,
- *minimální zásoba* – minimální úroveň zásob, je jí dosaženo těsně před novou dodávkou,
- *objednací zásoba* – úroveň zásoby, při níž je objednána další dávka. (Mulačová, 2013, str. 383)

3.4.2 Klasifikace modelů řízení cyklu zásob

Pro jednodušší orientaci v existujících modelech řízení zásob je vhodné tyto modely klasifikovat, a to dle Zajíčkové (2004) následovně:

1. Dle regulovatelnosti procesu doplňování zásob

- Regulované doplňování zásob – subjekt hospodařící se zásobou má možnost ovlivňovat svým rozhodnutím průběh doplňování zásob a tím i jejich průměrnou výši. V tomto případě je vhodné nalézt optimální strategii doplňování zásob.
- Náhodné doplňování zásob – doplňování zásob má převážně náhodný charakter. Pro tento případ existuje prozatím velmi málo modelů, proto podrobnější členění pozbývá smysl.


Dle druhu uspokojované potřeby

- Deterministické modely – podnik zná předem přesně velikosti potřeby, která má být ze zásoby uspokojena, není potřeba počítat s náhodnými výkyvy, není nutné vytvářet pojistnou zásobu. Deterministické modely se dále dělí na modely konstantní potřeby (neměnné v čase) a variabilní potřeby (potřeba se v čase mění předem známým způsobem).
- Stochastické modely – budoucí potřeba nebo délka pořizovací lhůty mají pravděpodobnostní charakter. Tato skupina modelů se dále dělí na modely statické (jednorázové potřeby) a dynamické (periodické doplňování zásob). U dynamických modelů rozlišujeme dále modely pro stacionární potřebu a modely pro nestacionární potřebu (adaptivní modely).

Dle režimu doplňování zásob

- Režim volných objednacích termínů – objednávka je vystavena vždy, jakmile zásoba klesne na určitou (signální) výši, je vystavena na optimální konstantní množství.
- Režim pevných objednacích termínů – objednávka se vystavuje jen v pevně daných termínech, které stanoví buď dodavatel, nebo subjekt hospodařící se zásobou. Výše objednávaného množství se zpravidla stanoví jako rozdíl mezi skutečným stavem zásob k danému termínu a doobjednací mezí.

Klasifikace modelů řízení zásob je znázorněna na Obrázek 9.



Obrázek 9 - Klasifikace modelů řízení zásob

Zdroj: Zajíčková, 2004

3.4.3 Modely deterministické

Deterministický pohyb zásob představuje budoucí poptávku, jejíž velikost i rozložení v čase přesně známe. Velikost potřeby je dopředu známá a není nutné počítat s náhodnými výkyvy, není potřeba vytvářet jakoukoliv pojistnou zásobu. Všechny deterministické modely optimalizují pouze obratovou složku zásoby a nákladové optimum se hledá pouze pomocí nákladů na skladování jednorázových nákladů na doplnění zásoby.

V praxi se jen zcela výjimečně vyskytují situace, které by nebyly ovlivněny nejistotou a mohly být prezentovány deterministickými modely. (Zajíčková, 2004)

Deterministické modely s konstantní potřebou

Economic Order Quantity

První matematický model pro řízení zásob, nazývaný Economic Order Quantity (EOQ), vypracoval v roce 1913 Ford W. Harris (1913) pro účely plánování výroby. Řadí se mezi jednoduktové deterministické dynamické modely a jde v podstatě o nejjednodušší model – model periodicky doplňovaných zásob s konstantní velikostí dodávky. (Lukáš, 2005, str. 101)

Model má následující předpoklady:


- poptávka je spojitá a konstantní, takže tempo čerpání zásob je neměnné,
- proces trvá nekonečně,
- neexistuje množstevní omezení (bez množstevní či skladové kapacity),
- doplnění zásob je okamžité,
- nedostatek není povolen,
- náklady nejsou závislé na čase ani na množství.
- zboží na sklad přichází pravidelně, což znamená, že dodávky přichází buď periodicky (perioda = délka doplňovacího cyklu), nebo okamžitě, a to v okamžiku, kdy zásoba klesne na určenou signální hladinu, dodávky mají vždy stejný objem. (Roach, 2005)

Cílem modelu je najít optimální velikost výrobní dodávky tak, aby byla výroba ekonomicky nejvýhodnější. Je potřeba vyvážit pořizovací náklady s náklady skladovacími.

K vývoji modelu se používá následující značení:

- TC – celkové roční náklady na systém zásob
- T – doba řízení skladu zboží (perioda v letech)
- Q – objednávkové množství
- I – zásoba (počet kusů)
- C – nákupní cena jednotky
- R – skladovací náklady na peněžní jednotku na jednotku času (rok)
- H – roční skladovací náklady na jednotku
- A – objednáací náklady na jednu objednávku dodávky zboží
- D – roční očekávaná poptávka

Na Obrázek 10 je znázorněn cyklus zásob vyjadřující doplňování a spotřebu zásob. Z obrázku je patrné, že sklad obsahuje průměrně $Q/2$ kusů. Periodu cyklu je možné vyjádřit vztahem $T = Q/D$, T je uvedeno v letech.



Obrázek 10 - Cyklus doplnění a spotřeby zásob ve skladu

Zdroj: Vlastní zpracování dle Roach, 2005.

Počet cyklů za rok, tedy také roční počet provedených objednávek, je dán vztahem D/Q . Celkové roční náklady na řízení zásob jsou potom následující:

$$TC = CD + A \frac{D}{Q} + H \frac{Q}{2}. \quad (13)$$

Optimální objednávací množství (od tohoto Economic Order Quantity) vychází z procesu hledání minima funkce celkových nákladů. Nejdříve je nutné funkci celkových nákladů derivovat podle Q a první derivaci následně položit nule, tedy

$$\frac{\delta(TC)}{\delta(Q)} = -\frac{AD}{Q^2} + \frac{H}{2} = 0. \quad (14)$$


Po vyjádření Q z rovnice získáme optimální množství Q^* :

$$Q^* = \sqrt{\frac{2AD}{H}}. \quad (15)$$

Z druhé derivace funkce je možné zjistit, zda jde skutečně o minimum, tedy

$$\frac{\delta^2(TC)}{\delta^2(Q)} = \frac{AD}{Q^3} > 0, \quad (16)$$

platí pro všechny kladné hodnoty Q .



Obrázek 11 - Vztah jednotlivých složek nákladů souvisejících se zásobami

Zdroj: Vlastní zpracování dle Roach, 2005.

Obrázek 11 ukazuje, v jakém vztahu jsou jednotlivé složky nákladů (skladovací náklady, náklady na objednávku) a celkové náklady s objednávacím množstvím. Je zde zachyceno také dříve zjištěné optimální objednávací množství. (Roach, 2005)

Uvedený vzorec pochází už z první poloviny 20. let 20. století a je znám pod různými názvy (Wilsonův, Harrisův-Wilsonův, Campův, Andlerův či „odmocninový“). (Horáková, 1998, str. 120)

Model EOQ je často modifikován pro různé způsoby zadávání potřebných vstupních dat, např. v případě potřeby respektování rabatu (množstevních slev závislých na objemu objednaného množství v dodávce). (Lukáš, 2005, str. 105)

Produkčně-spotřební model

Jako další model řízení zásob bývá zmiňován Produkčně-spotřební model (Production Order Quantity model, POQ), který je řazen mezi deterministické modely pro určení optimální velikosti dodávky.

Podstatou modelu je, že k doplnění zásoby zboží nedochází v jednom okamžiku dodávkou o jisté velikosti, nýbrž zásoba je doplňována postupně během určitého období, ve kterém současně dochází k výrobě, tedy ke spotřebě vytvářené zásoby. Proces doplňování zásob tedy probíhá současně s jejich čerpáním. Je potřeba, aby rychlost doplňování zboží byla větší než rychlost jeho čerpání. V okamžiku, kdy dosáhne okamžitá úroveň zásoby ve skladu předem dané úrovně, zastaví se doplňování, avšak čerpání vytvořené zásoby pokračuje po nějakou dobu dále. Až se zásoba spotřebuje, je znovu nastartován proces doplňování zásoby a cyklus se znovu opakuje. (Lukáš, 2005, str. 105)

V této podkapitole byly vybrány nejdůležitější základní modely pro řízení zásob. Další modely jsou pouze jejich modifikací, jako např. model periodicky doplňovaných zásob s konstantní velikostí dodávky s možností přechodného nedostatku, model periodicky doplňovaných zásob s konečnou rychlostí doplňování a s možností přechodného nedostatku, dále se literatura zabývá víceproduktovými modely. (Lukáš, 2005, str. 109 - 120)

Deterministické modely s proměnnou potřebou

Jde o situace, kdy se potřeba v jednotlivých obdobích mění předem známým způsobem (sezóna apod.). K nalezení optimálního řešení, které je dáno posloupností různých výrobních dávek, se používá postup dynamického programování vyvinutého R. C. Bellmanem. (Zajíčková, 2004)

3.4.4 Modely stochastické

Situace, v nichž budoucí potřeba nebo délka pořizovací lhůty mají charakter náhodně proměnných veličin, jsou prezentovány stochastickými modely. (Zajíčková, 2004)

Stochastické modely statické

Jde o situace, kdy je nutné v určitém období uspokojit potřebu ze zásoby, která je pořízena pouze jednorázově, a není možné další doplnění této zásoby. Je-li pořízena zásoba nižší než skutečná poptávka nebo je-li pořízena zásoba vyšší než skutečná poptávka, vznikají dodatečné náklady. V prvním případě jde o náklady z nedostatku pohotovostní zásoby, ve druhém případě vznikají náklady z nadbytečné zásoby. (Zajíčková, 2004)

Newsvendor model

Jde o matematický model spadající do kategorie stochastických statických modelů, který se zabývá problémem řízení jednodruhové zásoby s pravděpodobně vyjádřenou poptávkou pro jedno období. Prodávač musí na začátku prodejního období zvolit velikost objemu zásob. Rozhodnutí je možné provést pouze jednou, neexistuje možnost doplnění zásob v průběhu prodejního období. Poptávka po zboží je náhodná proměnná s pravděpodobnostním rozdělením. Cílem modelu je nalezení takové velikosti zásoby, která se bude nejlépe shodovat s budoucí poptávkou, a náklady z nedostatku či z přebytku zásoby budou minimální. (Lee, Homem-de-Mello and Kleywegt, 2012)

Stochastické modely dynamické

Pomocí těchto modelů obvykle hledáme optimální režim regulačních zásahů do zásobovacího procesu. Jako regulační zásah můžeme chápat výši dávky, kterou zásobu doplňujeme, a délku objednávkového intervalu, popř. délku dodávkového cyklu. Způsob využití těchto regulačních zásahů označujeme jako „objednávkový režim“ nebo také „režim doplňování zásob“. (Zajíčková, 2004)

V rámci dynamických modelů rozlišujeme dvě podskupiny podle toho, zda je model konstruován po pevné nebo volné objednacích termíny:

1. *Režim volných objednacích termínů* – zásoba je doplněna, až klesne na úroveň jistého signálního stavu. Délka objednávkového intervalu je vždy proměnlivá a závisí na intenzitě výdejů. Dávka, kterou zásobu doplňujeme, může být buď konstantní, nebo proměnná.


2. *Režim konstantní délky objednávkového intervalu* – množství, kterým zásobu doplňujeme, je proměnlivé. Toto množství pak závisí na zjištěném stavu zásob a očekávané potřebě. (Zajíčková, 2004)

Dynamické stochastické modely pak dále členíme na skupinu modelů stacionárních a modelů adaptivních (nestacionárních).

3. *Stacionární modely* – za stacionární považujeme ty modely, které předpokládají stacionární průběh spotřeby, tj. takový průběh, při němž potřeba nemá ani vzestupný či sestupný vývojový trend, ani sezónní výkyvy.
4. *Nestacionární modely* – existují vývojové trendy či sezónní výkyvy ve spotřebě. (Zajíčková, 2004)

3.4.5 Q-systém

Systém pro řízení zásob s pevnou velikostí dodávky a s různou frekvencí objednávek (Fixed-order quantity, reorder point, ROP) se řadí do skupiny stochastických modelů v režimu volných objednacích termínů a patří mezi nejpoužívanější modely řízení zásob. U Q-systému je stanovena signální hladina zásoby, která slouží ke krytí spotřeby do uskutečnění dodávky. Jestliže klesne hladina zásob na tuto úroveň, dojde k objednání. Délka intervalu mezi jednotlivými objednávkami je různá podle toho, kdy dojde k poklesu na signální úroveň. (Sanders, 2014)



Obrázek 12 - Schéma Q-systému


Zdroj: Sanders, 2014

System předpokládá, že všechny hodnoty proměnných se vyskytují při konstantní rychlosti a jejich hodnoty jsou známy. Například existuje předpoklad, že poptávka je stálá a bez výkyvů. Také doba potřebná pro dodání zásilky a skladovací náklady jsou známy a konstantní.

Q-systém se tedy používá nejčastěji tam, kde je poptávka relativně vyrovnaná a nedochází k příliš velkým výkyvům. Q-systém je považován za poměrně robustní a poskytuje vynikající výsledky i přes poměrně přísné předpoklady. (Sanders, 2014)

3.4.6 P-systém

P-systém řízení zásoby (Fixed-time period system, fixed order interval, FOI) má pevně stanoveny intervaly k objednání a velikost objednávek je stanovena podle kontroly okamžité zásoby. Je také řazen mezi stochastické dynamické modely zásob v režimu konstantní délky objednávkového intervalu. Systém také stanoví cílovou úroveň zásob, kterou chce po dodání objednávky udržet. Zásoby jsou kontrolovány například každý týden či měsíc a je vystavena objednávka pro obnovení stavu zásob na předem danou úroveň. Objednané množství se v každém období liší, jde o rozdíl mezi aktuální úrovní skladu a požadovanou úrovní. (Sanders, 2014)



Obrázek 13 - Schéma P-systému

Zdroj: Sanders, 2014

Dle literatury (Buxey, 2006) pracují systémy řízení zásob s periodickou kontrolou stavu zásob nejlépe. Je to hlavně proto, že různé položky zásob lze objednat najednou u jediného dodavatele, což může přinést množstevní slevy.

Pojistná zásoba v P-systému slouží k tlumení výkyvu poptávky v průběhu celého pevného objednacího cyklu a navazujícího intervalu porřízení zásoby. P-systém vyžaduje držení větší pojistné zásoby, jelikož dostupná zásoba není zjišťována v dostatečně častých intervalech a náhlý nárůst poptávky by mohl vést k vyprodání. Systém naopak umožňuje organizovanější nákup v pravidelných intervalech stejně jako kontrola dostupných zásob.

V literatuře je často provedeno srovnání modelů Q-systému a P-systému. Buxey (2006) považuje za rozumný hybridní model, tzv. *minimax*, který využívá periodické kontroly zásob jako P-systém, ale k objednávce dojde až po dosažení objednací úrovně jako u Q-systému. Navržený model se snaží vyloučit z objednávek neekonomické velikosti dodávek. Kromě toho nemusí vypočtená velikost objednávky odpovídat množství v balení či minimálnímu množství, které lze dodat.

3.5 Současné trendy modelů pro řízení zásob

Jak již bylo zmíněno dříve, první model pro stanovení velikosti dodávky byl Harissův model Economic Order Quantity (Harris, 1913). Základní EOQ model se zabývá problematikou jednoho typu zboží bez kapacitního omezení, s konstantní poptávkou. Při použití EOQ modelu lze jednoduše dojít k optimálnímu řešení.

Jelikož jsou uvedené podmínky velmi omezující a v drtivé většině případů neodpovídají praxi, byly ve druhé polovině 20. století vyvinuty propracovanější modely. Prvním ke zmínění je Economic Lot Scheduling Problem (ELSP, model ekonomického plánování dávek), kde je již zahrnuto kapacitní omezení (Rogers, 1958 a Elmaghraby, 1978). ELSP se již zabývá více produkty, ale zachovává předpoklad stálé poptávky a nekonečný časový horizont pro plánování. Vyřešení tohoto modelu je velmi obtížné, proto zde dominuje využití heuristik. (Zipkin, 1991)

Dalším odkloněním od klasického EOQ modelu bylo směrem k předpokladu dynamické poptávky. Wagner a Whitin (1958) vytvořili tzv. Wagner-Whitin model, který pracuje s konečným časovým horizontem pro plánování rozděleným do několika diskrétních období. Pro každou etapu je známa poptávka, která se může měnit v čase. V tomto modelu se však nepočítá s kapacitními omezeními a týká se pouze jednoho produktu. Lze zde jednoduše dojít k řešení. (Aggarwal a Park, 1993)

Pozdější generace modelů kombinovaly modely s různým kapacitním omezením a modifikací dynamických přístupů. K řešení problému stanovení velikosti dodávky bylo přidáno také plánování nákupu. (Drexler, Kimms a Seeanner, 1997)

V rámci literatury je věnována pozornost také přístupu pro stanovení pojistné zásoby v rámci dodavatelského řetězce. Simchi-Levi a Zhao (2005) se ve své studii zabývali stanovením velikosti pojistné zásoby v podmínkách stochastické doby pro dodávku zboží.

Za samostatnou, následně vyvinutou skupinu modelů se dají považovat modely s kazícím se zbožím. Do kazícího se zboží jsou například zahrnovány produkty, které podléhají morálnímu opotřebení, rychlé zkáze nebo se rozkládají. Modely pro kazící se zboží taktéž vycházejí z klasického EOQ modelu či Wagner-Whitinova modelu, který následně modifikují pro potřebné podmínky. Základní členění se opět odvíjí od povahy poptávky, a to na modely se stálou poptávkou, poptávkou proměnnou v čase, poptávkou

závislou na burze či na aktuální ceně, ale také se stochastickou poptávkou (Ahmed a kol., 2013; Skouri a kol., 2009) či časově proměnnou poptávkou. (Chang a Dye, 1999; Dye a Ouyang, 2005)

Speciální modely jsou vyvinuty pro případ přípustného opoždění platby, kde je zahrnuta platba úroků z prodlení, pro případ slevy na nákupní ceně se zahrnutím inflace a časové hodnoty peněz či model zásob s dvěma a více sklady. (Goyal a Giri, 2001)

3.6 Současné trendy v predikci časových řad pomocí Soft Computingu

Predikce časových řad je důležitou oblastí předpovědí, kdy je nutné získat dostatečné množství pozorování jedné proměnné v historii, aby bylo možné získaná data analyzovat a na základě zjištěných vztahů sestavit model pro prodloužení časové řady do budoucnosti.

V minulosti byl veškerý výzkum pro predikci časových řad věnován statistickým metodám a modelování pomocí technik klasických statistických disciplín. S vývojem metod Soft Computingu, především umělých neuronových sítí a později genetických algoritmů, se začalo uvažovat o spojení těchto metod s predikcí časových řad.

Historie propojení predikce časových řad a modelů umělých neuronových sítí sahá až do roku 1990, kdy se Tang a kol. (1990) a Sharda a Patil (1992) shodli, že pro časové řady s dlouhou historií mají modely umělé neuronové sítě a Box-Jenkinsonova metodologie srovnatelné výsledky. Hill a kol. (1996) ve svém výzkumu srovnali predikce více druhů časových řad (roční, čtvrtletní, měsíční) prostřednictvím umělých neuronových sítí a Box-Jenkinsonovy metodologie, přičemž prokázali, že modely umělých neuronových sítí mají mnohem lepší výsledky při predikci časových řad s menšími intervaly (měsíční, čtvrtletní). V případě ročních časových řad byly výsledky jednotlivých modelů srovnatelné. Obecně řečeno, modely umělé neuronové sítě byly efektivnější pro případ nespojitých časových řad.

Po prokázání, že jsou modely umělých neuronových sítí vhodným nástrojem pro predikci časových řad, vyvstala otázka, zda je nutné předzpracování dat pro predikci prostřednictvím umělých neuronových sítí. Nelson a kol. (1999) se pokusili vyvinout

model umělé neuronové sítě a použít jej na různě předzpracované časové řady, avšak získali velmi smíšené výsledky, ze kterých není možné vyvodit jasný závěr.

Hansen a Nelson (2003) vyvinuli model zpožděné neuronové sítě pro předzpracování časové řady, jehož výstupy následně využili jako vstupy pro model neuronové sítě s backpropagation, tedy s algoritmem zpětného šíření chyby, pro predikci. Architektura obou modelů umělé neuronové sítě byla optimalizována prostřednictvím genetických algoritmů. Pro ověření výkonnosti modelů byla použita makroekonomická časová řada. Ačkoliv výsledky umělých modelů neuronových sítí byly opět přesnější než ARIMA modely, autoři došli k závěru, že modely Box-Jenkinsonovy metodologie mohou být stabilnější a nejlepších výsledků může být dosaženo spojením těchto dvou metodik.

Porovnáním či spojením Box-Jenkinsonovy metodologie a metod umělých neuronových sítí se ve svém výzkumu věnoval Zhang. Pro využití výhod obou nástrojů byl vyvinut model kombinující ARIMA model a model umělé neuronové sítě, tedy lineárního a nelineárního modelování. Výsledky experimentálního porovnávání na reálných datech prokazují zvýšení přesnosti předpovědi konstruovaného modelu. (Zhang, 2003)

K významnějšímu výsledku Zhang došel v dalším výzkumu, kdy prověřoval vliv předzpracování dat na výkon predikce prostřednictvím umělých neuronových sítí. V jeho publikaci (Zhang a Qi, 2005) byla hodnocena efektivita sezónního a trendového očištění dat před jejich použitím pro predikci umělou neuronovou sítí. Získané výsledky byly následně srovnány s výsledky Box-Jenkinsonovy metodologie, konkrétně se SARIMA modelem. Bylo dokázáno, že předzpracování dat výrazně pozitivně ovlivňuje přesnost následující predikce prostřednictvím umělých neuronových sítí. Autoři potvrzují domněnku Nelsona a kol. (1999), že díky časové řadě očištěné o sezónní složku je možné docílit přesnější predikce s využitím umělých neuronových sítí. Také časová řada očištěná o trendovou složku vykazuje poměrně dobré výsledky. Za nejúčinnější metodu předzpracování dat autoři považují jak očištění o trendovou složku, tak očištění o sezónní složku pro využití k následné predikci.

Predikci časových řad se Zhang věnoval dále (Zhang, 2007), kdy vstup do modelu umělých neuronových sítí, tedy časová řada byla upravena přidáním šumu. Výzkum prokázal příznivý vliv tohoto předzpracování dat na následnou predikci.

Das a Chaudhury (2007) se pokusili o predikci prostřednictvím modelu umělé neuronové sítě časové řady prezentující týdenní objem prodeje obuvi. Z článku není patrné, jaký způsob předzpracování autoři použili. Lze tedy pouze vyvodit, že modely umělé neuronové sítě lze úspěšně použít pro predikci prodeje.

Speciální technika pro umělé neuronové sítě byla využita v dalším výzkumu (Sun et al. 2008), kdy byla použita technika extrémního učení, což je zvláštní algoritmus učení umělé neuronové sítě. Výsledky studie ukazují, že algoritmus extrémního učení může být považován za výkonnější než často používaný backpropagation, zvláště při predikci prodejů v módním průmyslu.

Porovnání umělých neuronových sítí s klasickými statistickými metodami představil Hamzaçebi (2008). Ve svém výzkumu navrhnul strukturu umělé neuronové sítě pro predikci časové řady se sezónním prvkem. Navržená struktura bere v úvahu sezónnost časové řady pro stanovení počtu vstupních a výstupních neuronů. Model byl verifikován na čtyřech reálných časových řadách. Výstupy navrženého modelu umělé neuronové sítě pro predikci časové řady byly porovnány s tradičními statistickými metodami a modely umělé neuronové sítě s jinou architekturou. Ze statistických metod byla pro porovnání zvolena Box-Jenkinsonova metodologie, a to ARIMA a SARIMA modely. Výsledky výzkumu pro predikci časových řad ukazují, že navržený model umělé neuronové sítě vykazuje nižší chybu predikce než jiné metody. Výstupy studie také dokazují, že navržený model je velmi spolehlivý, především pokud je sezónnost v časové řadě výrazná. Naopak pokud je sezónnost v použité časové řadě slabší, je doporučeno využít jiných struktur neuronové sítě.

Další výzkum již přistupuje k propojení metod Soft Computingu pro predikce časových řad z oblasti ekonomie. Sexton a Hignite (2014) využívají speciální algoritmus, který je možné přeložit jako algoritmus souběžně běžící optimalizace neuronové sítě (Neural Network Simultaneous Optimization Algorithm, NNSOA), který je založen nejen na umělých neuronových sítích, ale také na genetických algoritmech. Genetický algoritmus umožňuje v rámci umělé neuronové sítě lepší nalezení globálního optima a tím přesnější predikci oproti ostatním metodám, ať už na bázi umělých neuronových sítí, či statistiky.

3.7 Soft Computing při řízení zásob

3.7.1 Fuzzy logika a další pokročilé metody rozhodování

Expertní systémy byly již dříve hojně využívány pro řešení problematiky řízení zásob a plánování. Ve studii Du a Wolfe (1997) byla provedena rozsáhlá rešerše literatury zabývající se využitím fuzzy logiky a neuronových sítí v průmyslu, tedy i v problematice plánování a řízení zásob. Autoři studie zdůraznili především možnosti využití a možné přínosy fuzzy logiky v oblasti skladového hospodářství. Li, Kabadi a Nair (2002) vyvinuli dva modely využívající fuzzy prostředí pro řešení problematiky zásob v jednom období. V prvním modelu je pracováno se stochastickou poptávkou, skladovací náklady a náklady za nedostatek jsou fuzzy. Ve druhém modelu je pracováno s přesnými náklady, poptávka je typu fuzzy. V obou případech je cíl (zisk) fuzzy. Studie ukázala, že při řešení obou modelů je možné dojít k optimálnímu řešení.

Již v dřívější či v nedávné době se také objevilo několik studií zaměřených na fuzzy objednávky a optimalizace výrobního množství (Wang, Tang a Zhao, 2007, Yao, Chang a Su, 2000, Mondal a Maiti, 2003, Samanta a Al-Araimi, 2001). Např. Wang, Tang a Zhao (2007) ve svém článku analyzují fuzzy EOQ problematiku zásob, aniž by docházelo k nedostatku zásob. V modelu jsou objednávací náklady a skladovací náklady jako fuzzy proměnné a je konstruován fuzzy model. Navržený model byl ve studii otestován na reálných datech a dosáhl uspokojivých výsledků. Autoři se ale již nezmiňují o následném praktickém využití modelu.

Samanta a Al-Araimi, (2001) vyvinuli model pro skladové hospodářství založený na fuzzy logice. Model simuluje systém pro podporu rozhodování k udržení skladu hotových výrobků na určité úrovni, aby bylo dosaženo splnění kolísavé poptávky.

EOQ modelem obohaceným o fuzzy parametry se zabývali Mondal a Maiti (2003). Cíle minimalizace nákladů bylo dosaženo pomocí genetických algoritmů a nelineárního programování, metoda genetických algoritmů nabídla dokonce lepší výsledky. Autoři studie došli mimo jiné k závěru, že model využívající metod genetických algoritmů nabízí více alternativ spolu s optimálním řešením a tedy že jsou genetické algoritmy nejvhodnější metodou přispívající k rozhodování manažera.

V současné době se problematika týkající se skladového hospodářství, jako například objednacích množství, okamžik pro objednání zboží či problém dvou a více skladů, řeší pomocí multikriteriálního modelu pro zásoby. Úlohy pro stanovení velikosti dodávky byly řešeny také pomocí genetických algoritmů.

Chang, Yao, Huang a Chen (2006) rozšířili problematiku optimálního plánování velikosti dodávky o teorii fuzzy množin, poptávka a náklady jsou zde typu fuzzy. Autoři rozšiřují již dříve zmíněný Economic Lot-Size Scheduling Problem o fuzzy poptávku, jelikož se v reálném světě v poptávce po produktech často vyskytují odchylky. Další vybrané proměnné byly také typu fuzzy. V rámci výzkumu byl zkonstruován model genetických algoritmů, který by měl pomoci při optimalizaci ostrých proměnných. Výsledky výzkumu ukazují, že je vhodné využít fuzzy proměnné v případě použití ELSP modelu, doporučený způsob vychází z aktuálně zkonstruovaného modelu.

Pourakbar, Farahani a Asgari (2007) se zabývali čtyřstupňovým dodavatelským řetězcem obsahujícím jednoho dodavatele, výrobce, obchodníka a prodejce. V rámci celého dodavatelského řetězce je povolen nedostatek zboží, který se řeší objednaním i v případě chybějícího zboží na skladě (backordering). Cílem modelu je určit optimální nakupované množství v každé etapě dodavatelského řetězce spolu s minimalizací nákladů. Dále je studován efekt objednání v případě chybějících produktů na skladě na další prvky dodavatelského řetězce.

Fuzzy logika a pokročilé metody rozhodování byly pomocí nových koncepcí využívány v ekonomických procesech i nadále (Ioana et al., 2010 a Zhang, 2012).

Gaafar (2006) se ve své publikaci věnoval aplikaci genetických algoritmů při stanovení velikosti dodávky v případě externího skladu s deterministickou poptávkou vyvíjející se v čase. Výzkum ukázal velmi vysokou výkonnost metody genetických algoritmů především v případě krátkodobého plánovacího horizontu.

Megala a Jawahar (2006) se zabývají problémem stanovení velikosti dodávky ve specifických podmínkách. Pro vyřešení dynamického problému stanovení velikosti dodávky jsou sestaveny 4 modely z oblasti genetických algoritmů či umělých neuronových sítí, tedy z oblasti heuristik. Výsledky výzkumu prokázaly vhodnost využití metody genetických algoritmů, avšak také potvrdily, že využití modelu umělých neuronových sítí je vhodné pouze pro problémy s malým množstvím. Problematikou stanovení velikosti dodávky ve spojení s využitím heuristik za různých, často

specifických podmínek, se v polední době zabývalo více publikací, např. Şenyiğit et al (2013); Baciarello et al. (2013); Fazle Baki et al. (2014); Schulz, T. (2011); Beck et al. (2015); Kang a Lee (2013) a další.

3.7.2 Využití umělých neuronových sítí pro řízení zásob

Predikce poptávky hraje důležitou roli také v rámci řízení dodavatelského řetězce. Odhad budoucí poptávky po určitém produktu je základ pro vlastní systém doplňování zboží. V posledních letech bylo vyvinuto mnoho technik pro předpověď poptávky, každá s určitou výhodou i nevýhodou oproti jiným přístupům. (Aburto a Weber, 2007) Prostor pro vývoj nových přístupů a technik pro predikci poptávky po určitém druhu zboží či výrobků je tedy stále otevřen, především pro modely kombinující již prozkoumané techniky, využívající pouze pozitiva a snažící se potlačit již známé nevýhody použitých technik.

Aburto a Weber (2007) ve svém výzkumu prezentovali hybridní inteligentní systém kombinující Box-Jenkinsonovu metodologii (ARIMA a SARIMA modely) a modely umělých neuronových sítí s více vrstvami perceptronů pro predikci poptávky. Studie prokazuje vylepšení přesnosti předpovědi a navrhuje systém doplňování zboží do chilského supermarketu, který vede ke snížení úrovně zásob a zároveň ke snižování prodejních selhání.

Využitím umělých neuronových sítí při řešení problému velikosti dodávky pro řízení výroby se zabývá výzkum Gaafara a Choueikiho (2000), kteří vyvinuli plně funkční model pro případ deterministické poptávky měnící se v čase. V článku bylo prokázáno, že správně vyvinutý model neuronových sítí nabízí vhodnou alternativu ke stanovení velikosti dodávky při plánování zdrojů pro výrobu (Manufacturing Resource Planning, MRP). Sami autoři ovšem přiznávají, že nebyla dostatečně zohledněna problematika nákladů a vyvinutý model by se dal vylepšit využitím výpočtu pro optimum nákladů (nikoliv učení použitého v článku).

Hachicha (2011) řešil problém velikosti dodávky v dodavatelském řetězci simulací metamodelování prostřednictvím metod umělých neuronových sítí. Studovaný dodavatelský řetězec působí na trhu výroby na objednávku, tedy bez možnosti držení skladu a s limitovanou produkční kapacitou. Výsledky studie prokazují efektivnost, flexibilitu a možnost využití metody umělých neuronových sítí v praxi.

Dvě naposledy zmíněné vědecké publikace se zabývají aplikací neuronových sítí při stanovení velikosti dodávky pro výrobní podniky. Sami autoři přiznávají nedostatečné zohlednění potřeby minimalizace nákladů související s dodáním zboží. Zde se nabízí možnosti pro další výzkum, a to při využití neuronových sítí pro stanovení velikosti dodávky v oblasti obchodního podnikání a také se zahrnutím problematiky optimalizace nákladů.

Někteří autoři v posledních letech věnovali mnoho pozornosti tzv. Neuro-fuzzy systémům jako propojení technik fuzzy modelování a neuronových sítí. Neuro-fuzzy modely poskytují výhody fuzzy logiky i neuronových sítí, a to adaptabilitu, rychlou konvergenci a vysokou přesnost. (Shie-Jue a Chen-Sen, 2003)

Další model založený na umělých neuronových sítích byl vyvinut vědci Paul a Azaem (2011), kteří se snaží stanovit optimální úroveň zásob hotových výrobků. Vstupem do modelu jsou: poptávka po produktu, pořizovací náklady, skladovací náklady a materiálové náklady, výstupem modelu je úroveň zásob hotových výrobků. Byl vyvinut model umělé neuronové sítě s jednou skrytou vrstvou a algoritmem učení Backpropagation. Optimální nalezená architektura navrženého modelu je 4-10-1, tedy 4 vstupy, 10 neuronů ve skryté vrstvě a 1 výstup. Pro vyhodnocení přesnosti modelů umělé neuronové sítě bylo použito koeficientu determinace (R^2) a ukazatele MAPE (Mean Absolute Percentage of Error, střední absolutní procento chyby). Model byl testován na datech ze zpracovatelského průmyslu a výsledky výzkumu ukázaly, že zkonstruovaný model lze použít pro předpověď úrovně zásob hotových výrobků. Obecně řečeno, výzkum prokázal, že metody umělých neuronových sítí lze úspěšně použít pro optimalizaci zásob hotových výrobků pro všechny výrobní podniky.

He (2013) ve svém článku sestrojil model umělé neuronové sítě s vylepšenými parametry pro predikci úrovně zásob. Autor ve své studii tvrdí, že standardní neuronová síť s algoritmem učení backpropagation se potýká s problémy, jako jsou nízká míra konvergence či slabá přesnost predikce. Jako reakce na tyto problémy byla vytvořena nová neuronová síť s backpropagation, ale s vyšší mírou konvergence pro predikci úrovně zásob. Model je otestován na predikci úrovně zásob součástek pro automobilový průmysl. Výsledky studie prokázaly, že zdokonalený algoritmus nejen výrazně překračuje standardní algoritmy, ale dokonce překonává některé vylepšené algoritmy, a to v míře konvergence a také v přesnosti predikce.

Zmíněné publikace se zabývají aplikací umělých neuronových sítí pro stanovení velikosti objednávky ve výrobních podnicích. Řízení zásob v oblasti obchodního podnikání má specifické postavení už jen proto, že v tomto případě jde o klíčovou oblast managementu obchodních firem.

Jedním z úkolů disertační práce je proto prokázat, že metody umělých neuronových sítí lze taktéž s úspěchem použít pro optimalizaci zásob zboží v obchodních podnicích a sestavit vhodný model pro stanovení velikosti objednávky vedoucí k minimalizaci nákladů na objednání a držení zboží.

4 Výsledky dizertační práce

4.1 Popis aktuálního stavu analyzované společnosti

Společnost HPM TEC, s.r.o. byla založena v roce 1998, v době založení působila především jako výrobní podnik pro tepelné zpracování kovu. Od roku 2002 docházelo k postupnému rozšiřování obchodní činnosti, konkrétně obchodu se spojovacím materiálem.

V současné době se firma zabývá se prodejem spojovacího materiálu a službami v oboru stavebnictví a strojírenství. Prodávaný spojovací materiál je vyráběn jak výrobci v zemích EU, tak výrobci z asijských zemí. Dodavatelé jsou pečlivě vybíráni a kvalita výrobků podléhá pravidelným kontrolám.

Firma se zaměřuje na spojovací materiál určený pro profesionály. Nabídka spojovacího materiálu je zaměřena na firmy zabývajícími se dřevostavbami, krovky a dalšími konstrukcemi ze dřeva, pro firmy zabývajícími se výrobou a montáží plastových oken a dveří. Firma dodává širokému spektru odběratelů. Zákazníci společnosti jsou jednak firmy z oblasti obchodu (maloobchod i velkoobchod), jednak výrobní podniky především z oblasti stavebnictví, případně z oboru strojírenství a podobně. Ve výjimečných situacích podnik dodává také maloobtěratelům, sektor B2C je ale pokryt pouze minimálně.

Firma má v sortimentu přibližně 5000 typů zboží, které rozděluje do tří skupin, na velkoobrátkové (typ I.), maloobrátkové (typ II.) a doplňkové (typ III.). V případě zboží typu I. se firma snaží o 100 % uspokojení poptávky a drží pojistnou zásobu. Pro ostatní typy zboží firma drží menší skladové zásoby.

Velkoobrátkové zboží typu I. je pravidelně, přibližně čtyřikrát do roka, objednáváno od asijského dodavatele, přičemž dodávka je realizována lodní dopravou v přepravních kontejnerech a trvá přibližně 90 kalendářních dní. V tomto případě je cena zboží poměrně nízká, naopak prodejní cenu zboží výrazně zvyšují přepravní náklady. V případě, že zásoby klesnou příliš nízkou, kdy firma není schopna uspokojit současné či budoucí objednávky zákazníků a v blízké době neočekává velkou dodávku od asijských dodavatelů, je nucena objednat od evropských dodavatelů, kde je nákupní

cena zboží vyšší, přepravní náklady jsou pak nižší. Vzhledem k nákladům je však nákup z Evropy méně výhodný. U některých typů zboží je možné zadat objednávku také

Od roku 2003 využívá společnost pro řízení nákupu a prodeje podnikový informační systém. Eviduje zde mimo jiné nákupní i prodejní objednávky, pohyb zboží na skladu a náklady související se zbožím a s jeho pořízením.

V rámci ERP systému však není obsažena funkcionality pro stanovení termínu a velikosti nákupní objednávky. Ty jsou vystavovány zaměstnancem na základě aktuálního stavu skladu, znalostí a zkušeností z minulosti. K vyhodnocení potřeby objednání jsou využívána výhradně data z nedávné doby, maximálně půl roku zpětně. Delší časový interval je brán v potaz pouze jednou za čas pro zachycení sezónnosti.


Výzkum tedy bude zaměřen na návrh objednávkového cyklu podniku pro průmyslový podnik působící v oblasti obchodního podnikání. Výzkum se věnuje jednomu typu zboží s následujícími charakteristikami:

- zboží nabízené na českém trhu českým dodavatelem
- nekazící se zboží - nepodléhají morálnímu opotřebení, zkáze ani se nerozkládají
- průmyslové zboží
- zboží elektrotechnického charakteru
- materiál či součástky sloužící pro další zpracování.

4.2 Analýza časové řady

Jako vstupní data pro tvorbu modelu jsou použity informace o prodejkách velkoobchodní firmy se spojovacím materiálem. Jde o prodej nejjobrátkovějšího typu zboží, které má společnost ve svém sortimentu, sledovaný od ledna 2009 do prosince 2014.

Data jsou nejdříve agregována na údaje o prodejkách v jednotlivých měsících. Všechny měsíce jsou pak přepočteny na jednotkový časový interval, jsou očištěny na pracovní dny dle (7). Pro následující analýzu bylo použito nástroje Microsoft Office Excel, získaná data jsou zobrazena na následujícím grafu (Graf 1).




Graf 1 - Údaje o měsíčních prodejkách

Zdroj: Vlastní zpracování

Z grafu je jasně patrná sezónnost s roční periodou, trend je lineárně rostoucí. Vidíme, že variabilita hodnot v časové řadě roste, proto bude použita dekompozice multiplikativního modelu dle (9) $y_t = T_t * S_t * C_t * \varepsilon_t$. Multiplikativní model je možné převést na aditivní logaritmováním obou stran rovnice modelu dle (10).

4.2.1 Sezónní očištění


Pro očištění časové řady od sezónních vlivů je potřeba nejdříve určit sezónní faktor v aditivní formě. Tento faktor je stanoven pomocí centrovaných klouzavých průměrů, které jsou následně odečteny od původních hodnot. Sezónní faktory (pro aditivní model) interpretujeme ve stejných měrných jednotkách jako původní časovou řadu, sezónní indexy (pro multiplikativní model) se interpretují v procentech. Na následujícím grafu (Graf 2) lze vidět vývoj sezónních indexů časové řady (v %).



Graf 2 - Vývoj sezónních indexů v čase

Zdroj: Vlastní zpracování

Po odečtení sezónního faktoru od původní časové řady vznikne sezónně očištěná časová řada. Hodnoty sezónně očištěné časové řady jsou zobrazeny na následujícím grafu (Graf 3).



Graf 3 - Sezónně očištěná časová řada

Zdroj: Vlastní zpracování

4.2.2 Trendové očištění

Pro identifikaci trendu byl zvolen nejčastěji používaný typ trendové funkce, a to lineární trend. Ten vyjádříme ve tvaru

$$T_t = a_0 + a_1 t, \quad (17)$$

kde a_0 a a_1 jsou neznámé parametry a $t = 1, 2, \dots, n$ je časová proměnná. K odhadu parametrů a_0 a a_1 je použita metoda nejmenších čtverců, která dává nejlepší nevyhýlené odhady.

Pro numerické určení odhadu parametrů \hat{a}_0 a \hat{a}_1 přímky trendu je možné použít vzorce:


$$\hat{a}_0 = \bar{y} - a_1 * \bar{t}, \quad (18)$$

$$\hat{a}_1 = \frac{\sum t \cdot y_t - \bar{t} \cdot \sum y}{\sum t^2 - n \cdot \bar{t}^2}. \quad (19)$$

Rovnice odhadované trendové přímky má tvar:

$$T_t = 25,53 + 2,917t. \quad (20)$$

Časová řada očištěná od trendu vznikne opět odečtením hodnot trendů od časové řady. Časová řada očištěná od trendu je zobrazena na následujícím grafu (Graf 4).




Graf 4 - Trendově očištěná časová řada

Zdroj: Vlastní zpracování

4.2.3 Časová řada očištěná od sezónnosti a trendu

Jsou použity 3 typy předzpracování dat založené na předchozí dekompozici časové řady: trendové očištění, sezónní očištění a trendové i sezónní očištění. Jako vstupní soubor dat jsou použity 4 druhy časových řad, a to:

- originální časová řada (O) bez předzpracování,
- časová řada očištěná o trendovou složku (DT),
- časová řada očištěná o sezónní složku (DS),
- časová řada očištěná o sezónní i trendovou složku (DSDT), zobrazena na Graf 5.



Graf 5 - Časová řada očištěná o sezónní a trendovou složku (tzv. bílý šum)

Zdroj: Vlastní zpracování

4.3 Transformace dat

Data originální i předzpracované časové řady jsou následně transformována na standardizovanou formu za účelem získání konzistentních výsledků při využívání umělých neuronových sítí. Standardizace je provedena využitím následující rovnice:

$$t_i = \frac{x_i - \min(x_j)}{\max(x_j) - \min(x_j)}, \quad (21)$$

kde x_i je i -tý krok vybrané časové řady a t_i je odpovídající standardizovaná hodnota patřící do intervalu $\{0; 1\}$. (Das a Chaudhury, 2007)

4.4 Umělá neuronová síť pro predikci prodeje

4.4.1 Predikce prostřednictvím umělých neuronových sítí

Pro predikci časové řady je využito nástroje MathWorks MATLAB Neural Network Time Series Tool, který je využíván pro řešení nelineárních problémů časových řad pomocí dynamické neuronové sítě.

Nástroj MathWorks MATLAB Neural Network Time Series Tool umožňuje řešit 3 situace v rámci predikce časových řad:

- nelineární autotregresní model s externím vstupem (Nonlinear Autoregressive with External / Exogenous Input, NARX) predikující časovou řadu $y(t)$ se zadaným zpožděním d časové řady $y(t)$ a s externími vstupy časové řady $x(t)$;
- nelineární autoregresní model (Nonlinear autoregressive model, NAR), který predikuje časovou řadu $y(t)$ na základě zadaného zpoždění d a minulých hodnot $y(t)$;
- nelineární vstupně – výstupní model (Nonlinear Input – Output), který predikuje časovou řadu $y(t)$ na základě zadaných hodnot zpoždění d a minulých hodnot časové řady $x(t)$. Poslední jmenovaný model je vhodné využít pouze v případě, že nejsou známy minulé hodnoty $y(t)$, považuje se za méně přesný.


Z nabízených modelů je využít nelineární autoregresní model (Nonlinear autoregressive model, NAR), jelikož nejlépe odpovídá řešenému problému a podobě dostupných dat.

Tabulka 1 - Úsek časové řady jako vstup pro model neuronové sítě

Datum	O	DS	DT	DSDT
1.1.2010	0,093	0,138	0,218	0,405
1.2.2010	0,231	0,311	0,605	0,970
1.3.2010	0,207	0,191	0,508	0,528
1.4.2010	0,257	0,223	0,616	0,601
1.5.2010	0,217	0,166	0,483	0,399
1.6.2010	0,421	0,332	0,969	0,857
1.7.2010	0,450	0,306	1,000	0,748
1.8.2010	0,331	0,262	0,683	0,597
1.9.2010	0,342	0,258	0,682	0,559
1.10.2010	0,271	0,249	0,501	0,513
1.11.2010	0,328	0,355	0,601	0,750
1.12.2010	0,080	0,212	0,071	0,382

Zdroj: Vlastní zpracování

Jako vstup pro model umělé neuronové sítě je využita časová řada skládající se ze 72 měsíčních údajů o prodeji. Příklad datového souboru vstupních dat je uveden v Tabulka 1, jsou zde zahrnuty všechny 4 varianty vstupů do neuronové sítě – originální časová řada (O), časová řada očištěná o sezónní složku (DS), časová řada očištěná o trendovou složku (DT) a časová řada očištěná o sezónní i trendovou složku (DSDT). Datový soubor je náhodně rozdělen na části pro trénování, validaci a testování. Je použit nelineární autoregresní model neuronové sítě s jednou skrytou vrstvou a jednou výstupní vrstvou, přičemž počet skrytých neuronů a velikost zpoždění je možné dále definovat. Architektura umělé neuronové sítě pro predikci časové řady je zobrazena na následujícím obrázku (Obrázek 14).



Obrázek 14 - Architektura umělé neuronové sítě pro predikci časových řad

Zdroj: Vlastní zpracování s použitím MathWorks MATLAB Neural Network Time Series Tool

Pro trénování neuronové sítě je použit algoritmus Levenberg-Marquardt backpropagation, tedy algoritmus zpětného šíření chyby. Nástroj Neural Network Time Series Tool jiný algoritmus učení neumožňuje. Spolehlivost predikce je na základě vstupních a výstupních dat hodnocena pomocí MSE. Střední kvadratická chyba (Mean Squared Error, MSE) je vypočítána jako průměr druhých mocnin diferencí mezi výstupy a cílovými hodnotami. Nižší hodnoty MSE znamenají lepší výsledky, nula značí žádnou chybu.


Při návrhu modelu umělé neuronové sítě je důležité rozhodnout rozdělení dostupných dat na vzorek pro trénování, validaci a testování. 100 % datové sady je možné rozdělit na jednotlivé části v poměru 60/20/20, 70/15/15 či 80/10/10. Pro všechny varianty byla zkonstruovaná neuronová síť a následně otestovaná. Výsledky testování výkonnosti umělé neuronové sítě s různým poměrem vzorku pro trénování, validaci a testování jsou uvedeny v následující tabulce (Tabulka 2). Z výsledků vyplývá, že vzhledem k průměrným hodnotám MSE je nejlepší varianta 70 % vzorku pro trénování, 15 % vzorku pro validaci a 15 % vzorku pro testování.

Tabulka 2 – Hodnoty MSE pro výběr vzorků pro trénování, validaci a testování

	Trénování	Validace	Testování
60/20/20	0,0188	0,0262	0,0369
70/15/15	0,0189	0,0233	0,0283
80/10/10	0,0190	0,0236	0,0322

Zdroj: Vlastní zpracování

Data jsou dle předchozích výsledků rozdělena v poměru 70/15/15 a je provedena simulace predikce prostřednictvím navrženého modelu. Jsou konstruovány neuronové sítě pro různý počet neuronů ve skryté vrstvě. V úvahu připadají následující počty neuronů: 5, 7, 10, 12 a 15. Navržená architektura umělé neuronové sítě je simulovaná na 4 datových vzorcích – na originální časové řadě (O), na časové řadě očištěné o sezónní složku (DS), na časové řadě očištěné o trendovou složku (DT) a na časové řadě očištěné o sezónní i trendovou složku (DSDT).



Network Architecture

Choose the number of neurons and feedback delays.

Architecture Choices

Define a nonlinear autoregressive neural network. (narnet)

Number of Hidden Neurons:

Number of delays d:

Problem definition: $y(t) = f(y(t-1), \dots, y(t-d))$

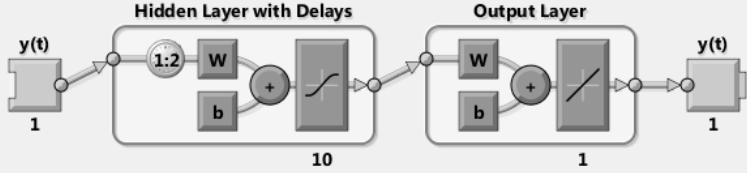
Recommendation

Return to this panel and change the number of neurons or delays if the network does not perform well after training.

The network will be created and trained in open loop form as shown below. Training with open loop (single-step) prediction is more efficient than with closed loop (multi-step) prediction because it allows us to supply the network with correct feedback inputs even as we train it to produce the correct feedback outputs.

After training, the network may be converted to closed loop form, or any other form, that the application requires.

Neural Network



Obrázek 15 - Volba architektury neuronové sítě

Zdroj: Vlastní zpracování s použitím MathWorks MATLAB Neural Network Time Series Tool

V Tabulka 3 jsou zachyceny výsledky (hodnoty MSE) získané při simulaci predikce prostřednictvím navrženého modelu umělé neuronové sítě.

Tabulka 3 - Hodnoty MSE při predikci prostřednictvím navrženého modelu NN

Počet skrytých neuronů	Typ dat	Trénink	Validace	Testování	Průměr
5	O	0,0227	0,0223	0,0137	0,0196
	DS	0,0102	0,0104	0,0116	0,0108
	DT	0,0352	0,0292	0,0129	0,0258
	DSDT	0,0224	0,0174	0,0233	0,0210
7	O	0,0237	0,0148	0,0137	0,0174
	DS	0,0074	0,0253	0,0077	0,0135
	DT	0,0335	0,0372	0,0284	0,0330
	DSDT	0,0240	0,0131	0,0132	0,0168
10	O	0,0214	0,0272	0,0123	0,0203
	DS	0,0116	0,0087	0,0070	0,0091
	DT	0,0277	0,0346	0,0280	0,0301
	DSDT	0,0201	0,0097	0,0119	0,0139
12	O	0,0162	0,0489	0,0112	0,0254
	DS	0,0070	0,0180	0,0092	0,0114
	DT	0,0229	0,0258	0,0315	0,0267
	DSDT	0,0146	0,0105	0,0196	0,0149
15	O	0,0155	0,0264	0,0287	0,0235
	DS	0,0888	0,0195	0,0088	0,0390
	DT	0,0340	0,0251	0,0279	0,0290
	DSDT	0,0205	0,0238	0,0215	0,0220

Zdroj: Vlastní zpracování

Z Tabulka 3 lze vyčíst mnoho důležitých poznatků. Především, že sezónně očištěná časová řada vykazuje nejlepší výsledky v případě většiny variant počtu skrytých neuronů. V případě vzorků pro trénink, validaci a testování vykazovala sezónně očištěná časová řada nejmenší hodnoty MSE. To značí, že je možné považovat metodu očištění časové řady o sezónní složku jako nejefektivnější metodu předzpracování dat pro modelování a predikci časových řad pomocí umělé neuronové sítě. Za spolehlivou metodu lze považovat také očištění o sezónní i trendovou složku, vykazuje druhou nejnižší hodnotu MSE ve většině případů.

Co se týče počtu skrytých neuronů, nejlepších výsledků dosahuje neuronová síť s 10 neurony ve skryté vrstvě.

4.4.2 Srovnání modelu umělé neuronové sítě a statistických metod

Po zjištění optimální architektury umělé neuronové sítě pro predikci časové řady bylo provedeno srovnání metody predikce prostřednictvím umělé neuronové sítě se statistickými metodami, konkrétně prostřednictvím ARIMA modelu. Výsledky jsou uvedeny v Tabulka 4.

Tabulka 4 - Srovnání predikce prostřednictvím ANN a ARIMA

Metoda	Typ dat	MSE
ANN s 10 skrytými neurony	O	0,0123
	DS	0,0070
	DT	0,0280
	DSDT	0,0119
ARIMA	O	0,0059

Zdroj: Vlastní zpracování

Z tabulky lze vyčíst, že model ARIMA vykazuje menší hodnoty MSE než model umělé neuronové sítě. Lze tedy usuzovat, že pro časové řady s jasně rozlišitelnou sezónností a trendem je ARIMA vhodnější predikční metoda.

V Tabulka 5 je uveden příklad predikovaných hodnot prostřednictvím ARIMA modelu a modelu umělé neuronové sítě pro všechny typy standardizované vstupní časové řady - originální časová řada (O), časová řada očištěná o sezónní složku (DS), časová řada očištěná o trendovou složku (DT) a časová řada očištěná o sezónní i trendovou složku (DSDT). V prvním sloupci je uvedena výchozí hodnota časové řady, se kterou jsou výstupy modelů porovnávány. V následujícím sloupci je uveden výsledek predikce prostřednictvím neuronových sítí a v případě originální časové řady je uveden i výsledek predikce prostřednictvím modelu ARIMA. Jak lze z tabulky vyčíst, v rámci standardizované časové řady (v intervalu od 0 do 1) nejde o příliš velkou odchylku od původních hodnot. Viditelně nejnižší chybovost vykazují výsledky predikce ARIMA modelem pro originální časovou řadu a predikce prostřednictvím modelu umělé neuronové sítě pro sezónně očištěnou časovou řadu.

Tabulka 5 - Příklad predikovaných hodnot prostřednictvím ARIMA a NN

O	DS		DT		DSDT			
	NN	ARIMA	NN		NN			
0,901	0,790	0,824	0,732	0,815	0,614	0,447	0,553	0,663
0,850	0,961	0,773	0,811	0,727	0,565	0,397	0,617	0,508
0,843	0,732	0,899	0,809	0,726	0,550	0,717	0,606	0,497
0,360	0,471	0,267	0,849	0,933	0,168	0,335	0,633	0,742
MSE	0,012	0,006	0,007		0,028		0,012	

Zdroj: Vlastní zpracování

Na druhou stranu výsledky predikce sezónně očištěné časové řady s využitím modelu umělé neuronové sítě jsou velmi blízko výsledkům modelu ARIMA. To naznačuje, že predikce prostřednictvím umělé neuronové sítě je taktéž vhodná pro predikci časové řady, přičemž zde nemusí být zjevná sezónnost.

Predikce prostřednictvím ARIMA modelu byla vyhodnocena jako méně vhodné řešení z důvodu menší univerzálnosti. Taktéž v případě praktického využití nemusí být vždy splněna podmínka dostatečně dlouhé časové řady o délce alespoň 50 pozorování. ARIMA model nelze v tomto případě označit za dostatečně spolehlivý.

Pro predikci časových řad byla zvolena metoda predikce prodeje prostřednictvím modelu umělých neuronových sítí, jelikož je schopna spolehlivě pracovat s časovými řadami s různě výraznou sezónností a trendem a není stanoven minimální počet pozorování.

4.5 Neuronová síť pro řízení objednávkového cyklu

Cílem výzkumu je využití metod umělých neuronových sítí pro řízení objednávkového cyklu podniku. Následující text se bude zabývat vývojem modelu umělé neuronové sítě, který může být následně použit pro optimalizaci úrovně zásob a tím může přispět ke zlepšení řízení zásob a objednávkového systému podniku.

Sada dat pro konstrukci i testování neuronové sítě byla poskytnuta spolupracující společností, podnikající v oblasti velkoobchodu se spojovacím materiálem. Společnost nakupuje v rámci dodavatelského řetězce od asijského výrobce a musí předpokládat dobu dodání objednaného zboží až 90 kalendářních dní od objednání. Získaná data představují údaje o prodeji nejobratkovějšího zboží z období od ledna 2009 do prosince 2014. Data týkající se prodejů jsou tedy totožná se vstupními daty pro model predikce prodeje, který byl diskutován dříve.

4.5.1 Proměnné modelu umělé neuronové sítě

Výstupem modelu je množství, které má být objednáno (počet jednotek zboží).

Jako vstupní parametry jsou použity proměnné:

- aktuální měsíční poptávka – což je poptávka po daném typu zboží v měsíci, kdy je zboží objednáváno;
- poptávka v příštích třech měsících - taktéž po konkrétním typu zboží, tento ukazatel je důležitý pro odhad úrovně zásob v době dodání objednaného zboží;
- poptávka ve třech měsících následujících po tříměsíčním objednávkovém cyklu - poptávka se týká konkrétního typu zboží, jde o odhad potřeby zásob v době, kdy bude aktuálně objednané zboží prodáváno;
- aktuální stav daného zboží na skladě;
- nákupní ceny na jednotku zboží;
- přepravní náklady na jednotku zboží.

Nákupní cenou je myšlena cena nakupovaného zboží bez jakýchkoliv přídatných nákladů. Přepravními náklady je podíl přepravních nákladů na jednotku zboží rozpočtených dle hmotností a clo. Nákupní cena a přepravní náklady dohromady tvoří pořizovací cenu. Je však nutné tyto náklady rozlišovat, jelikož jejich poměr je

různý při objednání zboží z různých zdrojů. Například při objednání zboží z asijských zemí je nákupní cena nízká a přepravní náklady vysoké, naopak při doobjednání zboží z Evropy je nákupní cena neúměrně vyšší a přepravní náklady nižší.

Rozdělení nákladů na pořízení zboží na nákupní cenu a přepravní náklady vychází z podmínek INCOTERMS, které mimo jiné definují, kdy hradí přepravní náklady dodavatel a kdy odběratel. V případě nákupu od asijského dodavatele platí podmínka FOB, kdy přepravní náklady přepravní náklady přechází z prodávajícího na nakupujícího okamžikem, kdy je zboží dodáno na palubu lodi v ujednaném přístavu nalodění. Od nalodění zboží firma tedy eviduje a hradí přepravní náklady. V případě od dodavatele z EU platí podmínka EXW, kdy kupující hradí přepravní náklady kompletně.


Pro jednotlivé vstupy byla sestavena korelační matice, která zobrazuje vztahy mezi jednotlivými vstupy do umělé neuronové sítě pro stanovení velikosti objednávky. Hodnoty korelační matice jsou zachyceny v následující tabulce (Tabulka 6).

Tabulka 6 - Korelační matice vstupů

	Aktuální poptávka	Poptávka příští 3M	Poptávka příští 3M za 3M	Stav skladu	Nákupní cena	Přepravní náklady
Aktuální poptávka	1,00	0,69	0,30	0,85	0,00	-0,32
Poptávka příští 3M	0,69	1,00	0,48	0,96	0,08	0,06
Poptávka příští 3M za 3M	0,30	0,48	1,00	0,40	-0,16	0,14
Stav Skladu	0,85	0,96	0,40	1,00	0,07	-0,09
Nákupní cena	0,00	0,08	-0,16	0,07	1,00	-0,10
Přepravní náklady	-0,32	0,06	0,14	-0,09	-0,10	1,00

Zdroj: Vlastní zpracování

Z korelační matice lze vyčíst, že až na výjimky nejsou vstupy do umělé neuronové sítě téměř vůbec korelovány. Tou výjimkou je vztah mezi stavem skladu a poptávkou v příštích třech měsících a taktéž stav skladu a aktuální poptávkou. Z povahy proměnných lze usuzovat, že zde jde spíše o náhodu či o důsledek stávajícího objednávkového systému firmy. V žádném případě nelze pozorovat korelaci mezi nákupní cenou a přepravními náklady.



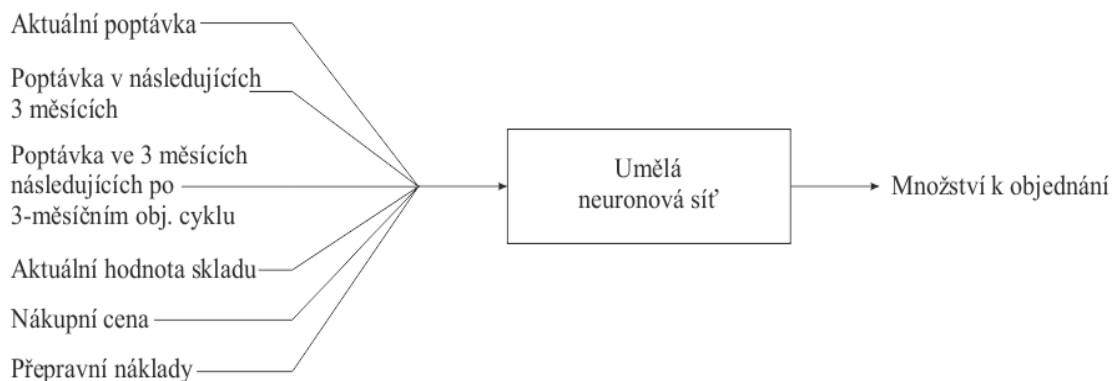
Graf 6 - Grafické znázornění korelační matice

Zdroj: Vlastní zpracování v programu STATISTICA

Z dalších možných vstupů byly zavrženy například skladovací náklady na jednotku zboží, jelikož jsou konstantní a neměly by tak vliv na výstup, taktéž výše pojistní zásoby. Za vhodný vstup také není považován typ či konkrétní dodavatel, u kterého bude objednáno, jelikož tato proměnná by se měla projevit ve výši skladovacích a přepravních nákladů. Mezi vstupy do modelu nejsou zahrnuty ani makroekonomické či cyklické ukazatele, ty by měly být zachyceny v proměnné týkající se poptávky.

4.5.2 Architektura modelu umělé neuronové sítě

V této studii je vyvinut model neuronové sítě pro stanovení optimálního množství objednávaného zboží pro optimalizaci aktuálního množství zboží na skladě. Pro konstrukci modelu umělé neuronové sítě je klíčový výběr vstupních a výstupních parametrů. Pro tento model je za vstupní proměnné vybráno 6 nejdůležitějších faktorů, které ovlivňují rozhodování o objednaném množství. Těmi jsou aktuální poptávka (měsíční), poptávka v příštích třech měsících, poptávka ve třech měsících následujících po tříměsíčním objednávacím cyklu, aktuální hodnota skladu, nákupní cena na jednotku zboží a přepravní náklady na jednotku zboží. Skladovací náklady nejsou jako vstup uvažovány, jelikož jsou na jednotku zboží konstantní. Jednotkou zboží je bráno tisíc kusů konkrétního zboží. Výstupním parametrem modelu je potom optimální nakoupené množství. Vstupy a výstupy modelu jsou znázorněny na Obrázek 16.



Obrázek 16 - Vstupy a výstup modelu umělé neuronové sítě

Zdroj: Vlastní zpracování

Tříměsíční objednávkový cyklus je zvolen na základě specifických dodavatelských podmínek ve společnosti, kdy doprava objednaného zboží od asijského dodavatele trvá právě 90 kalendářních dnů, tedy tři měsíce. Společnost tedy musí objednávat s tříměsíčním předstihem takové množství, které pokryje prodej zboží ve třech měsících následujících po jeho dodávce. Pojistná zásoba byla stanovena na 100 jednotek.

Model neuronové sítě byl zkonstruován pomocí programu MathWorks MATLAB. Pro návrh a konstrukci modelu neuronové sítě je potřeba provést následující kroky: získání vstupních a výstupních dat, konstrukce, trénování a ověření neuronové sítě. Po získání datového vzorku jsou data předzpracována na vzorek vstupně-

výstupních dat. Vstupní a výstupní data jsou standardizována na hodnoty z intervalu $\langle 0,1 \rangle$ pro získání standardizovaných hodnot pro využití umělé neuronové sítě. Příklad standardizované sady dat je v Tabulka 7.

Výstup modelu umělé neuronové sítě, tedy množství k objednání bylo upraveno tak, aby zajišťovalo optimální chování skladu. To znamená zajištění dostatečné pojistné zásoby (100 jednotek) a zároveň zabránění vzniku nadměrného neekonomického množství jednotek na skladě.

Celkem bylo získáno 29 datových sad obsahujících jak vstupní, tak výstupní hodnoty. Data byla náhodně rozdělena na 2 skupiny v poměru 79 % / 21 % na data pro fázi učení sítě, data pro trénování a data pro fázi testování sítě a verifikaci sítě.


Tabulka 7 - Ukázka standardizované sady dat

Aktuální poptávka	0,44	0,34	0,79	0,30	0,29	0,70
Poptávka v příštích 3 měsících	0,28	0,25	0,47	0,41	0,46	0,59
Poptávka ve 3 měsících následujících po 3 měsících	0,10	0,29	0,38	0,59	0,81	0,97
Aktuální hodnota skladu	0,28	0,25	0,57	0,36	0,36	0,57
Nákupní cena na jednotku zboží	0,89	0,00	0,47	0,86	0,30	0,54
Přepravní náklady na jednotku zboží	0,52	0,56	0,21	0,60	0,75	0,65
Výstup - množství	0,115	0,240	0,340	0,460	0,560	0,800

Zdroj: Vlastní zpracování

Pro sestavení modelu řízení zásob byl použit MathWorks MATLAB Neural Network Toolbox. Ten obsahuje funkce a aplikace pro modelování složitých nelineárních systémů, které není možné modelovat pomocí rovnice v uzavřeném tvaru. Pomocí Neural Network Toolbox je možné navrhovat, trénovat, vizualizovat a simulovat umělé neuronové sítě, rovněž tento nástroj může být použit pro aplikace, například pro rozpoznávání vzorů, shlukování, predikci časových řad či modelování a řízení dynamických systémů. (Beale a kol., 2015)

Pro účely predikce časové řady je použit model umělé neuronové sítě typu „Feed-forward backpropagation“, tedy algoritmus zpětného šíření chyby, se 6 vstupy, jednou skrytou vrstvou a jedním výstupem, přičemž stanovení optimálního počtu neuronů ve skryté vrstvě bude jeden z úkolů následujícího výzkumu. Trénovací funkce byly použity dvě, a to TRAINGDX a TRAINSCG, jako funkce pro učení byla použita LEARNGDM, jako přenosová funkce byla použita TANSIG a LOGSIG. Maximální počet trénovacích epoch byl stanoven na 1 000, maximální počet validačních kontrol byl stanoven taktéž na 1 000. Architektura navrženého modelu umělé neuronové sítě se 6 vstupy a 8 neurony ve skryté vrstvě a jedním výstupem, jak jej prezentuje nástroj MathWorks MATLAB Neural Network Toolbox, je zobrazena na Obrázek 17.



Obrázek 17 - Architektura navrženého modelu umělé neuronové sítě

Zdroj: Vlastní zpracování s použitím MathWorks MATLAB Neural Network Toolbox

Trénování umělé neuronové sítě je prováděno pomocí 24 vzorků dat obsahujících vstupní i výstupní data. Pro fázi trénování je spočítaná hodnota koeficientu determinace (R^2), jež slouží k ohodnocení výkonu umělé neuronové sítě během fáze trénování sítě. Hodnoty koeficientu determinace se pohybují v intervalu $\langle 0,1 \rangle$, přičemž cílem je určit přesnost následně predikovaných dat. Čím jsou hodnoty koeficientu determinace blíže 1, tím je neuronová síť považována za přesnější.

Po dosažení nejlepší možné hodnoty koeficientu R^2 je provedeno testování nově vzniklé natrénované neuronové sítě. Pro testování je použit vzorek 9 datových vektorů obsahující jak vstupní tak výstupní data, pro neuronovou síť je však použit pouze vstupní vektor. Výstup testování neuronové sítě je pak porovnán s reálnou hodnotou výstupu – tedy s reálně objednaným množstvím.

Výkon fáze testování je ohodnocenou metrikou chyby – střední čtvercová chyba (Mean squared error, MSE). MSE je průměrnou čtvercovou odchylkou mezi výstupy a cílovými hodnotami. Čím jsou hodnoty MSE nižší, tím menší je rozdíl, nula znamená žádnou chybu.

4.5.3 Výsledky modelu neuronové sítě

Výzkum se zabývá nalezením vhodné umělé neuronové sítě pro optimalizaci úrovně zásob a řízení objednávkového cyklu podniku. Pro nalezení nejlépe zkonstruované umělé neuronové sítě s optimální architekturou bylo sestaveno, trénováno a testováno 16 neuronových sítí s výukovou funkcí TRAINGDX a TRAINSCG a s přenosovou funkcí TANSIG či LOGSIG. Proměnlivý byl také počet neuronů ve skryté vrstvě. Vyhodnocení optimální neuronové sítě se orientovalo dle hodnoty MSE, zmíněné již dříve. Neuronové sítě s nižší hodnotou MSE a zároveň s hodnotou R^2 bližší 1 byly považovány za vhodnější.

Tabulka 8 - Hodnoty R^2 a MSE pro trénování a testování umělé neuronové sítě

	TRAINGDX				TRAINSCG			
Počet neuronů	8	10	12	15	8	10	12	15
TANSIG								
R^2	0,99	0,99	0,99	0,99	0,99	0,95	0,92	0,95
MSE	0,010	0,002	0,002	0,007	0,050	0,040	0,032	0,035
LOGSIG								
R^2	0,90	0,96	0,94	0,90	0,84	0,97	0,99	0,89
MSE	0,033	0,030	0,044	0,036	0,053	0,032	0,034	0,096

Zdroj: Vlastní zpracování

V tabulce lze vidět hodnoty R^2 a MSE zkonstruovaných neuronových sítí. Jsou zde uvedeny výsledky trénování a testování sítě s přenosovou funkcí TANSIG či

LOGSIG a s funkcí trénování TRAINGDX či TRAINSCG pro jednotlivé hodnoty počtu skrytých neuronů, které byly pro ANN použity. Z přehledu lze vyvodit, že obecně lepší výkon měly neuronové sítě s TRAINGDX funkcí trénování a TANSIG funkcí pro přenos. Nejnižší hodnoty MSE (0,002) a zároveň nejvyšší hodnoty R^2 (0,99) vykazuje neuronová síť s 10 a 12 skrytými neurony, naopak největší chybu (0,029) má neuronová síť s 15 skrytými neurony.

Obecně vzato, bylo zjištěno, že optimální architektura umělé neuronové sítě pro daný účel a s danými vstupními daty je architektura s funkcí učení TRAINGDX a funkcí přenosu TANSIG. Pro zjištění optimální architektury z pohledu počtu skrytých neuronů bylo sestrojeno, trénováno a testováno 9 umělých neuronových sítí s dříve zmíněnou architekturou, která byla vyhodnocena jako nejvhodnější pro daný účel.

Předmětem této části výzkumu je počet neuronů ve skryté vrstvě. Vyhodnocení optimální architektury z pohledu počtu skrytých neuronů neuronové sítě se opět řídí hodnotou MSE. Neuronové sítě s nižší hodnotou MSE a zároveň s hodnotou R^2 bližší 1 byly považovány za vhodnější. Výsledky analýzy a testování jsou uvedeny v následující tabulce (Tabulka 9).

Tabulka 9 - Hodnoty R^2 a MSE pro ANN s různým počtem skrytých neuronů

Počet neuronů	7	8	9	10	11	12	13	14	15
R^2	0,9995	0,9898	0,9944	0,9919	0,9978	0,9943	0,9977	0,9923	0,9947
MSE	0,0057	0,0100	0,0079	0,0024	0,0105	0,0017	0,0066	0,0041	0,0060

Zdroj: Vlastní zpracování

Z Tabulka 9 lze vyvodit, že nejnižší hodnoty MSE (0,017) a tím pádem nejlepší výkon měla neuronová síť s 12 skrytými neurony, přičemž největší spolehlivost sítě se pohybuje právě kolem tohoto počtu neuronů ve skryté vrstvě. Naopak největší chybu (0,105) má neuronová síť s 11 skrytými neurony. Z toho plyne, že neuronová síť s architekturou 6-12-1 je zvolena jako optimální model pro následnou predikci a dále pro návrh objednávkového systému firmy.

Tabulka 10 - Přehled optimální architektury umělé neuronové sítě

Vstupy	6 - aktuální měsíční poptávka - poptávka v následujících 3 měsících - poptávka ve 3 měsících následujících po 3 měsíčním objednávacím cyklu - aktuální hodnota skladu - nákupní cena na jednotku zboží - přepravní náklady na jednotku zboží
Výstupy	1 - množství k objednání
Typ sítě	Feed-forward backpropagation
Funkce trénování	TRAINGDX
Funkce učení	LEARNGDM
Hodnocení výkonu	MSE
Počet skrytých vrstev	1
Počet neuronů ve skryté vrstvě	12
Funkce přenosu	TANSIG
Parametry trénování	
Maximální počet epoch trénování (iterací)	1 000
Maximální čas trénování	Infinite
Minimální hodnota chyby	0

Zdroj: Vlastní zpracování

V tabulce 10 je uveden přehled architektury umělé neuronové sítě navrženého modelu, která se skládá ze 6 vstupních neuronů, 12 neuronů ve skryté vrstvě a jednoho výstupního neuronu. K nalezení optimální architektury sítě bylo použito ukazatelů R^2 a MSE, pomocí nichž byla každá neuronová síť vyhodnocena.

V Tabulka 11 jsou uvedeny skutečné výstupy neuronové sítě již převedené ze standardizovaného výstupu na reálné hodnoty množství k objednání. V prvním řádku jsou uvedeny hodnoty původního datového vzorku určeného pro testování, tedy reálně objednané množství. Ve druhém řádku jsou uvedené výstupy ze zkonstruované neuronové sítě s 11 skrytými neurony, která prokázala nejvyšší chybovost a ve třetím

řádku jsou výstupy neuronové sítě s 12 neurony ve skryté vrstvě, tedy zjištěné optimální architektury umělé neuronové sítě.

Tabulka 11 - Příklad výstupů umělé neuronové sítě

Původní hodnoty	358	420	470	530	580	700
11	358	445	372	533	509	684
12	342	434	450	512	595	734

Zdroj: Vlastní zpracování

Jak je z tabulky vidět, rozdíly mezi výstupy jednotlivých modelů umělé neuronové sítě nejsou příliš markantní, avšak v některých případech je navržené objednávací množství pro firmu nevýhodné. Ve 3. a 5. případě by objednané množství navržené neuronovou sítí s 11 skrytými neurony, bylo pro firmu vyloženě nedostačující, firma by musela čerpat z pojistné zásoby, při drobnějším odchýlení poptávky od predikované není schopna splnit veškerou poptávku, což by mohlo vést nejen ke snížení výnosů, ale také ke ztrátě některých zákazníků.

4.6 Model řízení objednávkového cyklu

Model řízení cyklu zásob vychází z navrženého modelu umělé neuronové sítě. Model neuronové sítě pro predikci objednaného množství stanoví velikost objednávky, která má být vystavena, tedy jaké množství daného zboží je potřeba objednat, aby byla splněna poptávka následující po tříměsíčním intervalu pro dodání zboží. Zatím však nebylo řečeno, kdy by měla být objednávka provedena.

V této chvíli je vhodné vrátit se k teorii týkající se řízení dodavatelského řetězce. Optimalizace objednávkového cyklu je jinými slovy snaha o dosažení podoby řetězce se synchronními toky. Tento typ řetězce je však pro nedostatečné splnění předpokladů téměř nedosažitelný, proto v rámci optimalizace podnikových procesů je vhodné především zdokonalit pozici podniku v řetězci s kontinuálními toky a využívat tzv. pull princip.


Dosud analyzovaný podnik využíval model náhodného doplňování zásob na základě znalostí a zkušeností objednavatele. Dodávka zvoleného typu zboží byla prováděna přibližně čtyřikrát v roce, v předem nespecifikovaných intervalech.

Zvolené zboží je dodáváno asijským dodavatelem spolu s dalšími typy zboží v jednom či více kontejnerech. Pro tuto situaci je pro firmu nejvýhodnější pro řízení cyklu zásob využít P-systému, který umožňuje objednání různých položek zásob u jednoho dodavatele.

Interval mezi jednotlivými momenty pro zjišťování stavu zásob a vystavení objednávek je stanoven na 3 měsíce, což vychází z dosavadní praxe, kdy bylo objednáváno přibližně čtyřikrát do roka. Zároveň tento interval koresponduje s dobou mezi vystavením objednávky a dodáním zboží. V ideálním případě by tedy ve chvíli, kdy dojde k naskladnění dodávky, mělo dojít ke kontrole aktuální zásoby a k doobjednání další dávky na základě predikované poptávky a dalších ukazatelů.

Oproti klasickému P-systému dle Sanderse (2014) nebude objednané množství rozdílem mezi aktuální úrovní skladu a požadovanou úrovní. Navržený model umělé neuronové sítě již obsahuje aktuální úroveň zásob jako jeden ze vstupů a výstupem modelu je již množství, které má být objednáno. V modelu umělé neuronové sítě pro stanovení velikosti objednávky je již zabudováno držení pojistné zásoby, která je na úrovni 100 jednotek.

Na následujícím grafu (Graf 7) je zobrazena podoba navrženého modelu pro řízení objednávkového cyklu daného podniku. Jde o podobu na základě minulých hodnot.



Graf 7 - Schéma navrženého modelu pro objednávkový cyklus

Zdroj: Vlastní zpracování

V následujícím textu dojde k ověření správnosti a použitelnosti navrženého modelu pro řízení objednávkového cyklu podniku na základě historických dat.

4.6.1 Ověření použitelnosti modelu řízení objednávkového cyklu

V následující tabulce (Tabulka 12) jsou uvedeny náklady na objednávku a skladovací náklady od roku 2011 do roku 2014. Tabulka obsahuje skutečné náklady, které firma na zboží vynaložila při svém dosavadním objednávacím systému (Skutečnost), a náklady, které by vynaložila, kdyby při svém rozhodování o nakupovaném množství využila navrhovaný model umělé neuronové sítě a model řízení objednávkového cyklu (Návrh).

Tabulka 12 - Kalkulace nákladů dle navrženého modelu

Rok		Objednací náklady	Skladovací náklady	Celkem	Rozdíl
2011	Skutečnost	180 679,00 Kč	4 608,60 Kč	185 287,60 Kč	
	Návrh	142 125,00 Kč	4 189,69 Kč	146 314,69 Kč	-38 972,91 Kč
2012	Skutečnost	302 301,50 Kč	3 549,35 Kč	305 850,85 Kč	
	Návrh	266 935,00 Kč	5 000,68 Kč	271 935,68 Kč	-33 915,17 Kč
2013	Skutečnost	290 860,50 Kč	5 239,80 Kč	296 100,30 Kč	
	Návrh	305 810,00 Kč	6 264,97 Kč	312 074,97 Kč	15 974,68 Kč
2014	Skutečnost	563 052,00 Kč	12 840,48 Kč	575 892,48 Kč	
	Návrh	382 710,00 Kč	6 776,17 Kč	389 486,17 Kč	-186 406,31 Kč

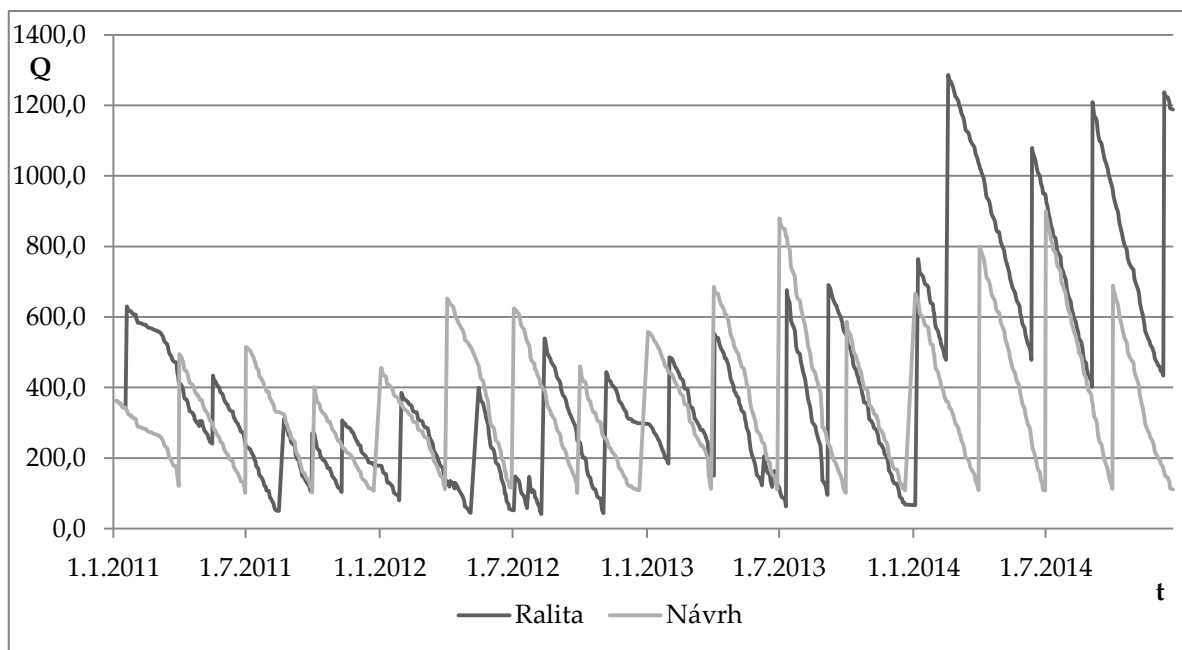
Zdroj: Vlastní zpracování

V Tabulka 12 lze vidět, že téměř ve všech letech dochází k markantní úspoře nákladů na pořízení a skladování zboží. Toho je docíleno optimalizací objednaného zboží dle očekávané poptávky vedoucí k optimalizaci objemu zboží drženého na skladě a tím skladovacích nákladů. K úspoře nákladů by nedošlo pouze v roce 2013. V tomto roce ve firmě reálně příliš poklesl objem zboží na skladě, a to mnohdy hluboko pod hranici pojistné zásoby. Neschopnost splnění objednávek lze považovat za nebezpečnější situaci pro firmu oproti vysokým nákladům na zboží, proto je navrhovaný objem nákupu stále považován za vhodnější. V roce 2014 se firma snažila zabránit nedostatku zboží na skladě, objednávala ve větším objemu, což vedlo k velmi

vysokým nákladům jak objednacím, tak skladovacím. Zde je rozdíl návrhu oproti skutečnosti největší.

Na následujícím grafu (Graf 8) je znázorněno srovnání úrovně zásob na základě reálných hodnot a dle navrženého modelu. Z grafu je patrné rovnoměrnější rozložení úrovně zásob v případě hodnot dle navrženého modelu, a to především pro rok 2014. Také je v grafu vidět, že v realitě zásoby mnohdy klesly pod hodnotu 100 jednotek, tedy pod stanovenou pojistnou zásobu, což by pro firmu mohlo znamenat nemožnost splnění objednávek.

Oproti tomu, v případě navrhovaného modelu zásoby klesly vždy pouze na úroveň pojistné zásoby a v tu chvíli došlo k přijetí již dříve objednané dodávky, kdy bylo zboží na sklad doplněno ve výši splňující poptávku v následujících 3 měsících. Navrhovaný model tedy umožňuje splnit veškerou poptávku, která je predikována s redukcí zbytečných nákladů na skladování.




Graf 8 - Srovnání úrovně zásob dle skutečnosti a návrhu

Zdroj: Vlastní zpracování

4.7 Ověření návrhů pro další typ zboží

Pro ověření navržených modelů a případně popis metodiky byla získána data o prodeji jiného typu zboží téže firmy ze stejného období a taktéž ze skupiny velkoobrátkového zboží typu I. Dle korelační analýzy je mezi původně zpracovanou časovou řadou a aktuálně zvolenou časovou řadou korelace 0,87, tedy poměrně silná závislost.

Data o prodeji jsou zobrazena na následujícím grafu (Graf 9).



Graf 9 - Údaje o prodeji dalšího typu zboží

Zdroj: Vlastní zpracování

Data byla zpracována stejným způsobem jako dříve. Bylo provedeno sezónní a trendové očištění a transformace dat. Opět byly získány 4 druhy vstupů pro umělou neuronovou síť pro predikci prodeje: originální časová řada (O), časová řada očištěná o sezónní složku (DS), časová řada očištěná o trendovou složku (DT) a časová řada očištěná o sezónní i trendovou složku (DSDT).

Datový soubor byl taktéž náhodně rozdělen na části pro trénování, validaci a testování v poměru 70/15/15 a je provedena simulace predikce časové řady prostřednictvím navrženého modelu, stejného jako v předchozím výzkumu. Jsou konstruovány neuronové sítě pro různý počet neuronů ve skryté vrstvě, stejně jako v předchozím výzkumu 5, 7, 10, 12 a 15.

Výsledky (hodnoty MSE) trénování, validace a testování neuronové sítě pro predikci časové řady jsou v následující tabulce (Tabulka 13).

Tabulka 13 - Hodnoty MSE pro ověření navrženého modelu NN pro jiný typ zboží

Počet skrytých neuronů	Typ dat	Trénink	Validace	Testování	Průměr
5	O	0,0158	0,0122	0,0115	0,0132
	DS	0,0124	0,0206	0,0174	0,0168
	DT	0,0249	0,0231	0,0259	0,0246
	DSDT	0,0220	0,0276	0,0280	0,0259
7	O	0,0118	0,0099	0,0128	0,0115
	DS	0,0103	0,0116	0,0117	0,0112
	DT	0,0364	0,0289	0,0211	0,0288
	DSDT	0,0185	0,0347	0,0288	0,0273
10	O	0,0164	0,0131	0,0036	0,0110
	DS	0,0146	0,0071	0,0032	0,0083
	DT	0,0181	0,0308	0,0291	0,0260
	DSDT	0,0234	0,0214	0,0166	0,0205
12	O	0,0161	0,0252	0,0109	0,0174
	DS	0,0146	0,0091	0,0103	0,0113
	DT	0,0369	0,0286	0,0172	0,0275
	DSDT	0,0230	0,0448	0,0176	0,0285
15	O	0,0124	0,0191	0,0181	0,0165
	DS	0,0065	0,0223	0,0176	0,0154
	DT	0,0136	0,0117	0,0218	0,0157
	DSDT	0,0250	0,0229	0,0161	0,0213

Zdroj: Vlastní zpracování

Z výsledků lze vyčíst, že umělá neuronová síť pro predikci prodeje vykazuje opět nejlepší výsledky v případě architektury s 10 neurony ve skryté vrstvě. Ze všech typů časových řad vykazuje stejně jako v předchozím výzkumu nejlepších výsledků sezónně očištěná časová řada.

Hodnoty MSE navíc ukazují, že navržený model umělé neuronové sítě je pro predikci časové řady nově testovaného typu zboží spolehlivější než v předchozím

případě. Samozřejmě nelze použít stejnou neuronovou síť na dříve naučených datech, nýbrž pouze stejnou architekturu umělé neuronové sítě, kterou je potřeba naučit na nově získaná data.

Lineární závislost časových řad podložená vypočtenou korelací a výsledky ověření predikce časové řady prostřednictvím navrženého modelu umělé neuronové sítě pro tento typ zboží napovídá, že pro tuto časovou řadu lze také použít navržené modely pro řízení objednávkového cyklu podniku. Lze také vycházet z faktu, že jde rovněž o velkoobrátkové zboží typu I a také zde platí tříměsíční objednávkový cyklus, kdy je zboží dodáváno asijským výrobcem.

Pro využití modelu objednávkového cyklu podniku lze přeučít již konstruovanou neuronovou síť pro stanovení velikosti objednávky v navržené architektuře na základě nových dat a model tak dále v nezměněné podobě používat.

4.8 Metodika pro využití navrženého modelu

Navržený model pro řízení objednávkového cyklu podniku lze využít také pro jiný typ zboží stejné povahy, s jinou délkou objednávkového cyklu a také v případě jiné obchodní společnosti.

Metodika vystavění modelu pro řízení objednávkového cyklu podniku lze rozdělit na několik na sebe navazujících kroků. Společnost, která se rozhodne model pro řízení objednávkového cyklu podniku aplikovat ve svém nákupním procesu, může postupovat podle následujícího doporučeného postupu řešení dané problematiky.

Sestavení modelu pro řízení objednávkového cyklu podniku se skládá z následujících kroků:

1. Získání vstupních dat, údajů o měsíčních prodejkách zboží v daném podniku.
2. Očištění časové řady o sezónní složku.
3. Naučení neuronové sítě pro predikci časové řady.
4. Predikce prodeje v následujících měsících prostřednictvím naučené neuronové sítě.
5. Získání informací o přepravních nákladech, nákupní ceně zboží a aktuální hodnotě skladu.
6. Naučení umělé neuronové sítě pro stanovení velikosti dodávky.
7. Stanovení velikosti dodávky, výstupu naučené umělé neuronové sítě na základě zadaných vstupů.
8. Sestavení objednávkového cyklu podniku na základě stanovené velikosti dodávky a P-systému.

5 Přínosy dizertační práce

Výstupem dizertační práce jsou modely napomáhající optimálnímu řízení objednávkového cyklu podniku a to model umělé neuronové sítě pro predikci prodejů vycházející z předchozí analýzy a dekompozice časových řad, dále model umělé neuronové sítě pro stanovení velikosti objednávky na základě daných vstupů, v neposlední řadě také samotný model pro řízení objednávkového cyklu podniku.

Výsledky dizertační práce vycházejí z dříve zmíněného stavu vědeckého poznání, a přispívají k němu jednak uceleným shrnutím aktuálního stavu a jednak rozšířením o nové poznatky. Přínosy dizertační práce jsou v následujícím textu vystiženy dle oblastí.

5.1 Teoretická oblast

Přínosy dizertační práce pro teoretickou oblast, tedy rozšíření současného stavu vědeckého poznání, jsou především v oblasti využití metod umělé inteligence a jejich dalšího propojení s teorií řízení objednávkového cyklu.

Dizertační práce přispěla k rozšíření teoretické oblasti v:

- sestavení uceleného přehledu a zmapování aktuálních poznatků v oblasti využití metod Soft Computingu v oblasti řízení objednávkového cyklu podniku a souvisejících činností;
- sumarizaci již prozkoumaných oblastí a odhalení případných mezer vhodných k dalšímu výzkumu;
- využití metod umělých neuronových sítí pro řízení objednávkového cyklu v obchodním podnikání, pro optimalizaci zásob zboží.

Dizertační práce se zabývá také vyplněním jedné volné mezery ve vědecké oblasti. Jak bylo zmíněno v rámci literární rešerše týkající se využití Soft Computingu při stanovení velikosti dodávky, bylo již dříve zjištěno, že dle Paul a Azaem (2011) lze metody umělých neuronových sítí úspěšně použít pro optimalizaci zásob hotových výrobků pro všechny výrobní podniky. V rámci dostupné literatury však není řešena otázka využití metod umělých neuronových sítí v obchodním podnikání, tedy při řízení

pohybu zboží v rámci obchodu či speciálně velkoobchodu. Na tuto oblast byl zaměřen výzkum v dizertační práci.

Bylo zjištěno, že metody umělých neuronových sítí a související sestrojené modely lze úspěšně použít pro stanovení velikosti dodávky a následně pro návrh objednávkového systému podniku z působící v oblasti obchodního podnikání. Dále bylo zjištěno, která architektura umělé neuronové sítě je pro tento účel nejvhodnější.

5.2 Praktická oblast

Přínosy pro praktickou oblast jsou zjevné. Jelikož data, podle kterých byly zpracovány analýzy i následný návrh, pocházely od existující společnosti, která projevila zájem o navržení modelu řízení zásob, lze výsledky dizertační práce uplatnit přinejmenším v této společnosti. Firma předpokládá zabudování výsledků dizertační práce do svého stávajícího informačního systému v podobě samostatného modulu s následným rozšiřováním funkcionalit dle aktuálních potřeb.

Navržený model pro predikci prodeje i pro návrh objednávkového systému podniku lze použít pro nekazící se průmyslové zboží elektrotechnického charakteru na českém trhu. Vhodný je spíše pro zboží sloužící jako materiál či součástka pro výrobky

Sestrojené a otestované modely lze využít buď po částech, nebo dohromady. Manažeři obchodních společností jistě ocení možnost predikce prodeje, a to především v případě prodeje se sezónními výkyvy a jistým trendem.

Praktický je také model umělé neuronové sítě pro stanovení velikosti dodávky, která má v sobě již zakomponovanou pojistnou zásobu. Některé vstupy, především poptávku v následujících třech měsících a poptávku ve třech měsících následujících po tříměsíčním objednávkovém cyklu, lze samozřejmě přizpůsobit dle délky objednávkového cyklu kteréhokoliv podniku a zkonstruovanou neuronovou sít' s danou architekturou naučit dle nových požadavků.

Některé výstupy dizertační práce by bylo možno využít i v jiných oblastech podnikového managementu, nejen v oblasti logistiky či obchodní logistiky. Například v marketingu při stanovení ceny nabízeného zboží či pro podporu prodeje v méně vytížených měsících.

5.3 Pedagogická oblast

Výsledky dizertační práce lze využít taktéž v oblasti pedagogiky. Dizertační práce poskytuje ucelený pohled na řešenou problematiku. Dále umožňuje propojení dvou vědeckých a pedagogických disciplín, a to řízení dodavatelského řetězce, tedy logistiku, a pokročilých metod rozhodování.

Nově získané poznatky lze využít v obou oblastech pedagogiky, například v předmětech Obchodní logistika, Pokročilé metody analýz a modelování či Operační a systémová analýza II. Předměty Statistika či Aplikovaná statistika lze obohatit o příklad využitý v dizertační práci, který se týká analýzy a dekompozice časových řad.

Modely navržené v rámci dizertační práce lze dále rozšířit či aplikovat v bakalářských a diplomových pracích vedených na Fakultě podnikatelské VUT v Brně. Je možné aplikovat po případném rozšíření model pro řízení objednávkového cyklu podniku v jiné společnosti zabývající se obchodním podnikáním.

6 Závěr

Dizertační práce pojednává o využití Soft Computingu při řízení objednávkového cyklu podniku. Cílem předkládané dizertační práce je navržení modelu pro řízení objednávkového cyklu podniku s využitím pokročilých metod rozhodování. V rámci dizertační práce je navržen model umělých neuronových sítí s vhodnou architekturou pro řízení zásob v rámci řízení dodavatelského řetězce ve společnosti působící v oblasti obchodního podnikání.

Úkolem teoretické části dizertační práce bylo vystihnout aktuální trendy v oblasti modelů pro řízení objednávkového cyklu podniku v rámci dodavatelského řetězce v přímé návaznosti na možnosti využití pokročilých metod rozhodování v této problematice.

První část dizertační práce byla věnovaná metodice využití následně v praktické části dizertační práce nejen při sestavování cílového modelu. V této části práce byly představeny vědecké metody a metody Soft Computingu, především umělé neuronové sítě.

Další část práce se zabývá analýzou aktuálního stavu řešené problematiky, tedy rešerší literatury z oblasti Supply Chain Managementu, a jeho velmi důležité součásti – modelů pro řízení zásob a plánování nákupu. V rámci rešerše literatury je představen aktuální stav vědeckého poznání v oblasti predikce časových řad pomocí metod umělé inteligence, a to především pro predikci prodeje na základě minulých dat, a také poznatků z oblasti využití metod Soft Computingu při řízení zásob či objednávkového cyklu podniku.

Třetí, praktická část dizertační práce obsahuje postupy vedoucí ke splnění hlavního cíle práce. Je zde navržen model umělé neuronové sítě pro predikci prodeje s vhodnou architekturou spolu se související analýzou časových řad jakožto vstupů do modelu umělé neuronové sítě. Dále je navržen model umělé neuronové sítě pro stanovení velikosti objednávky na základě stanovených vstupů, taktéž s vhodnou architekturou modelu umělé neuronové sítě. Na základě navržených modelů umělých neuronových sítí je sestaven samotný model pro řízení objednávkového cyklu podniku, jehož vhodnost je ověřena v rámci porovnání s aktuálně využívaným systémem.

Celá sada dat pro konstrukci i testování neuronové sítě byla poskytnuta spolupracující společností podnikající v oblasti velkoobchodu se spojovacím materiálem. Společnost nakupuje v rámci dodavatelského řetězce od asijského výrobce a musí předpokládat dobu dodání objednaného zboží až 90 kalendářních dní od objednání. Získaná data představují údaje o prodeji nejobrátkovějšího zboží z období od ledna 2009 do prosince 2014. Poskytnutá data jsou vstupem jak pro neuronovou síť pro predikci prodeje, tak pro model neuronové sítě pro stanovení velikosti objednávky. Jde tedy o sekundární zdroj dat.

Dizertační práce přináší ucelený pohled na uvedenou problematiku, včetně přínosů pro oblasti vědy, praxe a pedagogiky. Zároveň otevírá prostor pro vytvoření dalších námětů pro následný výzkum či aplikace v oblasti praxe. Základní model pro řízení objednávkového cyklu podniku z oblasti obchodního podnikání je možné modifikovat pro specifické typy zboží, například bez charakteristické sezónnosti či méně obrátkového zboží.

V dizertační práci je splněn hlavní cíl práce stejně jako dílčí cíle práce. Z výsledků dizertační práce je možné sestavit komplexní objednávkový systém podniku působící v oblasti obchodního podnikání.

Výsledky výzkumu, v rámci kterého je dizertační práce zpracována, jsou publikovány v návaznosti na specifický výzkum *Efektivní využití ICT a kvantitativních metod pro optimalizaci podnikových procesů* (zahájení: 01. 01. 2015, ukončení: 31. 12. 2016).

7 Seznam použitých zdrojů

- 1) ABURTO, L., WEBER, R. Improved supply chain management based on hybrid demand forecasts, *Applied Soft Computing*, 2007. Vol. 7, no. 1, pp. 136-144.
- 2) AGGARWAL, A., PARK, J. K., KRARUP, J. Improved Algorithms for Economic Lot Size Problems: An O(mn)-Algorithm for Structured Problems. *Operations Research*. 1993. Vol. 41, no. 3, pp. 155-180. DOI: http://dx.doi.org/10.1007/springerreference_6865.
- 3) AHMED, M. A., AL-KHAMIS, T. A., BENKHEROUF, L. Inventory models with ramp type demand rate, partial backlogging and general deterioration rate. *Applied Mathematics and Computation*, 2013. Vol. 219, no. 9, pp. 4288-4307. DOI: 10.1016/j.amc.2012.09.068. ISSN 00963003. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0096300312009800>
- 4) AISSAOUI, N., HAOUARI, M., HASSINI, E. Supplier selection and order lot sizing modeling: A review. *Computers & Operations Research*. 2007. Vol. 34, no. 12, pp. 3516-3540. DOI: <http://dx.doi.org/10.1016/j.cor.2006.01.016>.
- 5) ARLT, J. a ARLTOVÁ, M. *Ekonomické časové řady: [vlastnosti, metody modelování, příklady a aplikace]*. 1. vyd. Praha: Grada. 2007. ISBN 978-80-247-1319-9.
- 6) BAILY, P. J. et al. *Purchasing principles and management*. 9th ed. Harlow: Financial Times Prentice Hall, 2005, xiv, 427 s. ISBN 0-273-64689-3.
- 7) BACIARELLO, L., M. DAVINO, R. ONORI, M. M. SCHIRALDI. Lot Sizing Heuristics Performance. *International Journal of Engineering Business Management*. 2013. Vol 5, pp. 1-10. DOI: 10.5772/56004. ISSN 1847-9790. Dostupné z: http://www.intechopen.com/journals/international_journal_of_engineering_business_management/lot-sizing-heuristics-performance
- 8) BEALE, M. H., M. T. HAGAN, H. B. DEMUTH. MATHWORKS. *Neural Network Toolbox: User's guide*. Natick, MA, 2015.
- 9) BECK, F. G., E. H. GROSSE, R. TEßMANN. An extension for dynamic lot-sizing heuristics. *Production*. 2015. Vol. 3, no. 1, pp. 20-35. DOI:

10.1080/21693277.2014.985390. ISSN 2169-3277. Dostupné z:
<http://www.tandfonline.com/doi/full/10.1080/21693277.2014.985390>

- 10) BOX, G. E., JENKINS, G. M. Time series analysis: Forecasting and control. In *Holden-Day series in time series analysis*. Holden-Day. 1976.
- 11) BUDÍKOVÁ, M., M. KRÁLOVÁ a B. MAROŠ. *Průvodce základními statistickými metodami*. 1. vyd. Praha: Grada. 2010. Expert (Grada). ISBN 978-80-247-3243-5.
- 12) BUXEY, G. Inventory control systems: theory and practice. *Int. J. Information and Operations Management Education*. 2006. Vol. 1, no. 2, pp. 158-170.
- 13) CIPRA, T. *Analyza časových řad s aplikacemi v ekonomii: celostátní vysokoškolská učebnice pro stud. matem.-fyz. fakult studijních oborů 11 Fyzikálně matematické vědy*. 1. vyd. Praha: Státní nakladatelství technické literatury. 1986. ISBN 04-012-86.
- 14) DAS, P., CHAUDHURY, S. Prediction of retail sales of footwear using feedforward and recurrent neural networks. *Neural Computing and Applications*. 2007. Vol. 16, no. 4-5, pp. 491-502. Dostupné z:
<http://link.springer.com/10.1007/s00521-006-0077-3>.
- 15) DOSTÁL, P., RAIS, K., SOJKA, Z. *Pokročilé metody manažerského rozhodování: pro manažery, specialisty, podnikatele a studenty : konkrétní příklady využití metod v praxi*. 1. vyd. Praha: Grada, 2005, 166 s. ISBN 8024713381.
- 16) DOSTÁL, P. *Pokročilé metody analýz a modelování v podnikatelství a veřejné správě*. Vyd. 1. Brno: Akademické nakladatelství CERM, 2008, 340 s. ISBN 978-80-7204-605-8.
- 17) DOSTÁL, P., *Soft computing v podnikatelství a veřejné správě: Díl I.*, Vydání první. Brno: Akademické nakladatelství CERM, 2015.
- 18) DREXL, A., KIMMS, A., SEEANNER, F. Lot sizing and scheduling — Survey and extensions. *European Journal of Operational Research*. 1997. Vol. 99, no. 2, pp. 143-154. DOI: http://dx.doi.org/10.1007/978-3-658-02089-7_7.
- 19) DYE, C.-Y., OUYANG, L.-Y. An EOQ model for perishable items under stock-dependent selling rate and time-dependent partial backlogging. *European Journal of Operational Research*. 2005. Vol. 163, no. 3, pp. 776-783. Dostupné z:
<http://linkinghub.elsevier.com/retrieve/pii/S0377221703008099>.

- 20) DU, T. C. - T., WOLFE, P. M. Implementation of fuzzy logic systems and neural networks in industry. *Computers in Industry*. 1997. Vol. 32, no. 3, pp. 261-272. DOI: 10.1016/S0166-3615(96)00074-7. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0166361596000747>.
- 21) ELMAGHRABY, S. E. The Economic Lot Scheduling Problem (ELSP): Review and Extensions. *Management Science*. 1978. Vol. 24, no. 6, pp. 587-598. DOI: <http://dx.doi.org/10.1287/mnsc.24.6.587>.
- 22) FÁBRY, Jan. *Matematické modelování*. 1. vyd. Praha: Professional Publishing, 2011. 180 s. ISBN 978-80-7431-066-9.
- 23) FAZLE BAKI, M., B. A. CHAOUCH, W. ABDUL-KADER. A heuristic solution procedure for the dynamic lot sizing problem with remanufacturing and product recovery. *Computers*. 2014. Vol. 43, no. 2014, pp. 225-236. DOI: 10.1016/j.cor.2013.10.001. ISSN 03050548. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0305054813002943>
- 24) GAAFAR, L. Applying genetic algorithms to dynamic lot sizing with batch ordering. *Computers*. 2006. Vol. 51, no. 3, pp. 433-444. DOI: 10.1016/j.cie.2006.08.006. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0360835206001057>
- 25) GAAFAR, L. K., CHOUEIKI, M. H. A neural network model for solving the lot-sizing problem. *Omega*. 2000. Vol. 28, no. 2, pp. 175-184. DOI: [http://dx.doi.org/10.1016/s0305-0483\(99\)00035-3](http://dx.doi.org/10.1016/s0305-0483(99)00035-3).
- 26) GOYAL, S. K., GIRI, B. C. Recent trends in modeling of deteriorating inventory. *European Journal of Operational Research*. 2001. Vol. 134, no. 1, pp. 1-16. DOI: [http://dx.doi.org/10.1016/s0377-2217\(00\)00248-4](http://dx.doi.org/10.1016/s0377-2217(00)00248-4).
- 27) HACHICHA, W. A simulation metamodelling based neural networks for lot-sizing problem in MTO sector. *International Journal of Simulation Modelling*. 2011. Vol. 10, no. 4, pp. 191-203. DOI: 10.2507/IJSIMM10(4)3.188. Dostupné z: http://www.ijssimm.com/Full_Papers/Fulltext2011/text10-4_191-203.pdf.
- 28) HAMZACEBI, C. Improving artificial neural networks' performance in seasonal time series forecasting. *Information Sciences*. 2008. Vol. 178, no. 23, pp. 4550-4559.

- 29) HANSEN, J. V., NELSON, R. D. Forecasting and recombining time-series components by using neural networks. *Journal of the Operational Research Society*. 2003. Vol. 54, no. 3, pp. 307-317.
- 30) HARRIS, F. W. How Many Parts to Make at Once. In: *Factory, The Magazine of Management*. 1913. Vol. 10, no. 2, pp. 135-136, 152.
- 31) HE, W. An Inventory Controlled Supply Chain Model Based on Improved BP Neural Network. *Discrete Dynamics in Nature and Society*. 2013. Vol. 2013, no. 1, pp. 1-7,
- 32) HENDL, J. *Kvalitativní výzkum: základní teorie, metody a aplikace*. 2., aktualiz. vyd. Praha: Portál, 2008. 407 s. ISBN 978-80-7367-485-4
- 33) HENDL, J. *Přehled statistických metod: analýza a metaanalýza dat*. 4., rozš. vyd. Praha: Portál, 2012. ISBN 978-80-262-0200-4.
- 34) HINDLS, Richard. *Statistika pro ekonomy*. 8. vyd. Praha: Professional Publishing. 2007. ISBN 978-80-86946-43-6.
- 35) HILL, T., O'CONNOR, M., REMUS, W. Neural network models for time series forecasts. *Management science*. 1996. Vol. 42, no. 7, pp. 1082-1092.
- 36) HORÁKOVÁ, H. *Řízení zásob: Logistické pojetí, metody, aplikace, praktické úlohy*. 3.přepr.vyd. Praha: Profess Consulting. 1998. 236 s. ISBN 80-852-3555-2.
- 37) HOŘEJŠÍ, B. et al. *Mikroekonomie*. 5., aktualiz. vyd. Praha: Management Press. 2010. 574 s. ISBN 978-80-7261-218-5.
- 38) HOUCK, C. R., JOINES, J. A., KAY, M. G. A genetic algorithm for function optimization: a Matlab implementation. *NCSU-IE TR*. 1995. Vol. 95, no. 09, pp. 1-14.
- 39) HUDEC, O a kol. *Štatistické metódy v ekonomických vedách*. 1. vyd. Košice: Elfa. 2007. ISBN 978-80-8086-059-2.
- 40) CHANG, H. J., DYE, C. Y. An EOQ model for deteriorating items with time varying demand and partial backlogging. *Journal of the Operational Research Society*. 1999. pp. 1176-1182.
- 41) CHANG, P.-T., YAO, M.-J., HUANG S.-F., CHEN, C.-T. A genetic algorithm for solving a fuzzy economic lot-size scheduling problem. *International Journal of Production Economics*. 2006. Vol. 102, no. 2, pp. 265-288. DOI:

- 10.1016/j.ijpe.2005.03.008. Dostupné z:
<http://linkinghub.elsevier.com/retrieve/pii/S0925527305000770>.
- 42) CHOPRA, S., MEINDL, P. *Supply chain management: strategy, planning, and operation*. 3rd ed. Upper Saddle River: Pearson Prentice Hall, c2007, xv, 536 s. ISBN 0-13-173042-8.
- 43) Institut biostatistiky a analýz Masarykovy univerzity. Umělá inteligence: Biologická analogie. *Matematická biologie: E-learningová učebnice* [online]. [cit. 2016-03-16]. Dostupné z:
<http://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--biologicka-analogie>
- 44) IOANA, A., MIREA, V. a BĂLESCU, C. Economic processes study through Fuzzy Logic. *Journal of Economic Computation And Economic Cybernetics Studies And Research*. 2010. Vol. 44, no. 2, pp. 129-137.
- 45) JUROVÁ, M. *Výrobní procesy řízené logistikou*. 1. vyd. Brno: BizBooks, 2013. ISBN 978-80-265-0059-9.
- 46) KANG, H.-Y., A. H. I. LEE. A stochastic lot-sizing model with multi-supplier and quantity discounts. *International Journal of Production Research*. 2013. Vol. 51, no. 1, pp. 245-263. DOI: 10.1080/00207543.2012.674649. ISSN 0020-7543. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/00207543.2012.674649>
- 47) KOZEL, R., MYNÁŘOVÁ, L., SVOBODOVÁ, H. *Moderní metody a techniky marketingového výzkumu*. 1. vyd. Praha: Grada. 2011. 304 s. ISBN 978-80-247-3527-6.
- 48) KRIŽKO, I. SCM: Supply Chain Management: Optimalizace dodavatelského řetězce skrývá potenciál k získání konkurenční výhody. In: *System Online* [online]. IT SYSTEM 10/2002. 2002 [cit. 2014-02-10]. Dostupné z:
<http://www.systemonline.cz/clanky/scm-supply-chain-management.htm>.
- 49) KUBA, Martin, *Neuronové sítě*. Brno, 1995.
- 50) KVASNIČKA, M., VAŠÍČEK, O. *Úvod do analýzy časových řad*. Ekonomicko-správní fakulta Masarykovy univerzity, Brno. 2001.

- 51) LEE, S., HOMEM-DE-MELLO T., KLEYWEGT, A. J. Newsvendor-type models with decision-dependent uncertainty. In: *Mathematical Methods of Operations Research*. 2012. pp. 189-221. ISSN 1432-2994. DOI: 10.1007/s00186-012-0396-3.
- 52) LI, L., KABADI, S. N., NAIR, K. P. K. Fuzzy models for single-period inventory problem. *Fuzzy Sets and Systems*. 2002. Vol. 132, no. 3, pp. 273-289. DOI: 10.1016/S0165-0114(02)00104-5. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0165011402001045>.
- 53) LUKÁŠ, L. *Pravděpodobnostní modely*. 1. vyd. V Plzni: Západočeská univerzita v Plzni. 2005. 208 s. ISBN 80-704-3388-4.
- 54) MULAČOVÁ, V., P. MULAČ. *Obchodní podnikání ve 21. století*. 1. vyd. Praha: Grada, 2013. ISBN 978-80-247-4780-4.
- 55) MARČEK, M., PANČÍKOVÁ, L., MARČEK, D. *Ekonometria a soft computing*. Žilina: Žilinská univerzita v Žiline, 2008.
- 56) MEGALA, N., JAWAHAR, N. Genetic algorithm and Hopfield neural network for a dynamic lot sizing problem. *The International Journal of Advanced Manufacturing Technology*. 2006. Vol. 27, no. 11-12, pp. 1178-1191.
- 57) MOLNÁR, Z. *Úvod do základů vědecké práce: SYLABUS pro potřeby semináře doktorandů* [online]. 2011 [cit. 25.10.2013]. Dostupné z: web.fame.utb.cz/cs/docs/Z__klady_v__deck___pr__ce.doc.
- 58) MONDAL, S., MAITI M. Multi-item fuzzy EOQ models using genetic algorithm. *Computers*. 2003. Vol. 44, no. 1, pp. 105-117. DOI: 10.1016/S0360-8352(02)00187-0. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0360835202001870>.
- 59) NELSON, M., HILL, T., REMUS, W., O'CONNOR, M. Time series forecasting using neural networks: Should the data be deseasonalized first? *Journal of forecasting*. 1999. Vol. 18, no. 5, pp. 359-367.
- 60) NENES, G., PANAGIOTIDOU, S., TAGARAS, G. Inventory management of multiple items with irregular demand: A case study. *European Journal of Operational Research*. 2010. Vol. 205, no 2, pp. 313-324. DOI: 10.1016/j.ejor.2009.12.022. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0377221710000020>.

- 61) PAUL, S. K., AZAEEM, A. An artificial neural network model for optimization of finished goods inventory. *International Journal of Industrial Engineering Computations*. 2011. Vol. 2, no. 2, pp. 431-438.
- 62) POURAKBAR, M., FARAHANI, R. Z., ASGARI, N. A joint economic lot-size model for an integrated supply network using genetic algorithm. *Applied Mathematics and Computation*. 2007. Vol. 189, no. 1, pp. 583-596. DOI: 10.1016/j.amc.2006.11.116. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0096300306016328>.
- 63) PERNICA, P. *Logistika pro 21. století: (Supply chain management)*. Vyd. 1. Praha: Radix, 2005. ISBN 80-860-3159-4.
- 64) RAIS, K., DOSKOČIL, R. *Operační a systémová analýza I: studijní text pro prezenční a kombinovanou formu studia*. Vyd. 1. Brno: Akademické nakladatelství CERM, 2011, 125 s. ISBN 978-80-214-4364-8.
- 65) ROACH, B. Origin of the Economic Order Quantity formula; transcription or transformation? *Management Decision*. 2005. Vol. 43, no. 9, pp. 1262-1268. DOI: 10.1108/00251740510626317. Dostupné z: <http://www.emeraldinsight.com/10.1108/00251740510626317>.
- 66) ROGERS, J. A Computational Approach to the Economic Lot Scheduling Problem. *Management Science*. 1958. Vol. 4, no. 3, pp. 264-291. DOI: <http://dx.doi.org/10.1287/mnsc.4.3.264>.
- 67) SAMANTA, B., AL-ARAIMI, S. A. An inventory control model using fuzzy logic. *International Journal of Production Economics*. 2001. Vol. 73, no. 3, pp. 217-226. DOI: 10.1016/S0925-5273(00)00185-7. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0925527300001857>.
- 68) SANDERS, N. Operations Management Defined. In: *FT Press: Financial Times* [online]. Jan 23, 2014 [cit. 2016-03-04]. 2014. Dostupné z: <http://www.ftpress.com/articles/article.aspx?p=2167438&seqNum=7>.
- 69) SCHULZ, T. A new Silver–Meal based heuristic for the single-item dynamic lot sizing problem with returns and remanufacturing. *International Journal of Production Research*. 2011. Vol. 49, no. 9, pp. 2519-2533. DOI:

- 10.1080/00207543.2010.532916. ISSN 0020-7543. Dostupné z:
<http://www.tandfonline.com/doi/abs/10.1080/00207543.2010.532916>.
- 70) ŞENYIĞIT, E., M. DÜĞENCI, M. E. AYDIN, M. ZEYDAN. Heuristic-based neural networks for stochastic dynamic lot sizing problem. *Applied Soft Computing*. 2013. Vol. 13, no. 3, pp. 1332-1339. DOI: 10.1016/j.asoc.2012.02.026. ISSN 15684946. Dostupné z:
<http://linkinghub.elsevier.com/retrieve/pii/S1568494612001196>.
- 71) SHARDA, R., PATIL, R. Neural networks as forecasting experts: an empirical test. In *Proceedings of the International Joint Conference on Neural Networks*. 1990. Vol. 2, pp. 491-494.
- 72) SHIE-JUE, L., CHEN-SEN, O. A neuro-fuzzy system modeling with self-constructing rule generation and hybrid SVD-based learning. *IEEE Transactions on Fuzzy Systems*. 2003. Vol. 11, no. 3, pp. 341-353. DOI:
10.1109/TFUZZ.2003.812693. Dostupné z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1203793>.
- 73) SKOURI, K., KONSTANTARAS, I., PAPACHRISTOS S., GANAS, I. Inventory models with ramp type demand rate, partial backlogging and Weibull deterioration rate. *European Journal of Operational Research*. 2009. Vol. 192, no. 1, pp. 79-92. DOI: 10.1016/j.ejor.2007.09.003. ISSN 03772217. Dostupné také z:
<http://linkinghub.elsevier.com/retrieve/pii/S0377221707009162>.
- 74) SEGER, J., HINDLS, R. *Statistické metody v tržním hospodářství*. 1.vyd. Praha: Victoria Publishing, 1995, 435 s. ISBN 80-7187-058-7.
- 75) SEXTON, R. S., HIGNITE, M. A. Forecasting Daily Retail Sales Using a Modified Genetic Algorithm Neural Network. *International Journal of Information, Business and Management*. 2014. Vol. 6, no. 1. ISSN 2076-9202.
- 76) SIMCHI-LEVI, D., ZHAO, Y. Safety Stock Positioning in Supply Chains with Stochastic Lead Times. *Manufacturing*. 2005. Vol. 7, no. 4, pp. 295-318. DOI: 10.1287/msom.1050.0087. ISSN 1523-4614. Dostupné také z:
<http://pubsonline.informs.org/doi/abs/10.1287/msom.1050.0087>.

- 77) STADTLER, H., KILGER, C. *Supply chain management and advanced planning: concepts, models, software and case studies*. 3rd ed. Berlin: Springer. c2005. 512 s. ISBN 3-540-22065-8.
- 78) SUN, Z.-L. et al. Sales forecasting using extreme learning machine with applications in fashion retailing. *Decision Support Systems*. 2008. Vol. 46, no. 1, pp. 411-419. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0167923608001371>.
- 79) ŠIROKÝ, J. *Publikování a presentace výsledků vědy a výzkumu*. Olomouc: Moravská vysoká škola Olomouc. 2010. 54 s. ISBN 978-80-87240-41-0. Dostupné z: http://www.mvso.cz/Files/WEB/APSYS/72Publikovani_a_presentace_vysledku_VaV.pdf.
- 80) ŠÍMA, J., NERUDA, R. *Teoretické otázky neuronových sítí*. Vyd. 1. Praha: Matfyzpress, 1996.
- 81) TANG, Z., DE ALMEIDA, C., FISHWICK, P.A. Time series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*. 1991. Vol. 57, no. 5, pp. 303-310.
- 82) TETTAMANZI, A., TOMASSINI, M. *Soft computing: integrating evolutionary, neural, and fuzzy systems*. New York: Springer, c2001, xiii, 328 p. ISBN 35-404-2204-8.
- 83) WANG, X, TANG, W., ZHAO, R. Fuzzy Economic Order Quantity Inventory Models Without Backordering. *Tsinghua Science*. 2007. Vol. 12, no. 1, pp. 91-96. DOI: 10.1016/S1007-0214(07)70014-7. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6076184>.
- 84) WAGNER, H. M., WHITIN, T. M. Dynamic Version of the Economic Lot Size Model. *Management Science*. 1958. Vol. 5, no 1, pp. 89-96. DOI: <http://dx.doi.org/10.1287/mnsc.5.1.89>.
- 85) YAO, J.-S., CHANG, S.-C., SU J.-S. Fuzzy inventory without backorder for fuzzy order quantity and fuzzy total demand quantity. *Computers*. 2000. Vol. 27, no. 10, pp. 935-962. DOI: 10.1016/S0305-0548(99)00068-4. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0305054899000684>.

- 86) ZAJÍČKOVÁ, P. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, Fakulta stavební. *Klasifikace modelů zásob*. Brno, 2004. Dostupné z:
http://www.fce.vutbr.cz/veda/dk2004texty/pdf/05_Ekonomika%20a%20rizeni%20stavebnictvi/5_02_Ekonomika%20stavebniho%20podniku/Zajickova_Petra.pdf.
- 87) ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 2003. Vol. 50, pp. 159-175.
- 88) ZHANG, G. P. A neural network ensemble method with jittered training data for time series forecasting. *Information Sciences*. 2007. Vol. 177 no. 23, pp. 5329-5346. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0020025507003003>.
- 89) ZHANG, G. P., Qi, M. Neural network forecasting for seasonal and trend time series. *European journal of operational research*. 2005. Vol. 160, no. 2, pp. 501-514.
- 90) ZHANG, T. A Monte Carlo Analysis for Stochastic Distance Function Frontier. *Inzinerine Ekonomika-Engineering Economics*. 2012. Vol. 23, no. 3, pp. 250-255.
- 91) ZIPKIN, P. H. Computing Optimal Lot Sizes in the Economic Lot Scheduling Problem. *Operations Research*. 1991. Vol. 39, no. 1, pp. 56-63. DOI: http://dx.doi.org/10.1007/springerreference_6988.

Seznam použitých zkratk a symbolů

MA	Moving Average model, model klouzavého průměru
AR	Autoregressive model, autoregresní model
ARMA	Autoregressive Moving Average model, smíšený model autoregresního klouzavého průměru
ARIMA	Autoregressive Integrated Moving Average model, integrovaný model autoregresního klouzavého průměru
SAR	Seasonal Autoregressive model, sezónní autoregresní procesy
SMA	Seasonal Moving Average model, sezónní procesy klouzavých průměrů
SARMA	Seasonal Autoregressive Moving Average model, sezónní model autoregresního klouzavého průměru
SARIMA	Seasonal Autoregressive Integrated Moving Average model, sezónní integrovaný model autoregresního klouzavého průměru
ANN	Artificial Neural Networks, umělé neuronové sítě
NN	Neural Networks, neuronové sítě
NAR	Nonlinear autoregressive model, nelineární autoregresní model
NARX	Nonlinear Autoregressive with External / Exogenous Input, nelineární autotregresní model s externím vstupem
MSE	Mean Squared Error, střední kvadratická chyba
ME	Mean Error, střední chyba odhadu
MAE	Mean Absolute Error, střední absolutní chyba
MAPE	Mean Absolute Percentage of Error, střední absolutní procento chyby
R^2	koeficient determinace
SCM	Supply Chain Management, řízení dodavatelského řetězce
ERP	Enterprise Resource Planning, plánování podnikových zdrojů
MRP	Manufacturing Resource Planning, plánování zdrojů pro výrobu
O	Original time series, originální časová řada
DS	Deseasonalized time series, časová řada očištěná o sezónní složku

DT	Detrended time series, časová řada očištěná o trendovou složku
DSDT	Detrended and deseasonalized time series, časová řada očištěná o sezónní i trendovou složku

Seznam grafů

Graf 1 - Údaje o měsíčních prodejkch	70
Graf 2 - Vývoj sezónních indexů v čase	71
Graf 3 - Sezónně očištěná časová řada	71
Graf 4 - Trendově očištěná časová řada.....	72
Graf 5 - Časová řada očištěná o sezónní a trendovou složku (tzv. bílý šum).....	73
Graf 6 - Grafické znázornění korelační matice	83
Graf 7 - Schéma navrženého modelu pro objednávkový cyklus	91
Graf 8 - Srovnání úrovně zásob dle skutečnosti a návrhu	93
Graf 9 - Údaje o prodejkch dalšího typu zboží.....	94

Seznam obrázků

Obrázek 1 - Biologický neuron.....	26
Obrázek 2 - Umělý neuron.....	27
Obrázek 3 - Grafy aktivačních funkcí.....	28
Obrázek 4 - Schéma vícevrstevné neuronové sítě	28
Obrázek 5 - Znázornění metody nejmenších čtverců	31
Obrázek 6 - Postup zpracování dizertační práce.....	40
Obrázek 7 - Procesní cykly dodavatelského řetězce.....	42
Obrázek 8 - Subprocesy jednotlivých procesů v dodavatelském řetězci.....	43
Obrázek 9 - Klasifikace modelů řízení zásob	50
Obrázek 10 - Cyklus doplnění a spotřeby zásob ve skladu	52
Obrázek 11 - Vztah jednotlivých složek nákladů souvisejících se zásobami.....	53
Obrázek 12 - Schéma Q-systému.....	56
Obrázek 13 - Schéma P-systému	57
Obrázek 14 - Architektura umělé neuronové sítě pro predikci časových řad.....	76
Obrázek 15 - Volba architektury neuronové sítě	77
Obrázek 16 - Vstupy a výstup modelu umělé neuronové sítě	84
Obrázek 17 - Architektura navrženého modelu umělé neuronové sítě.....	86

Seznam tabulek

Tabulka 1 - Úsek časové řady jako vstup pro model neuronové sítě	75
Tabulka 2 – Hodnoty MSE pro výběr vzorků pro trénování, validaci a testování	76
Tabulka 3 - Hodnoty MSE při predikci prostřednictvím navrženého modelu NN.....	78
Tabulka 4 - Srovnání predikce prostřednictvím ANN a ARIMA.....	79
Tabulka 5 - Příklad predikovaných hodnot prostřednictvím ARIMA a NN	80
Tabulka 6 - Korelační matice vstupů	82
Tabulka 7 - Ukázka standardizované sady dat.....	85
Tabulka 8 - Hodnoty R^2 a MSE pro trénování a testování umělé neuronové sítě	87
Tabulka 9 - Hodnoty R^2 a MSE pro ANN s různým počtem skrytých neuronů.....	88
Tabulka 10 - Přehled optimální architektury umělé neuronové sítě	89
Tabulka 11 - Příklad výstupů umělé neuronové sítě.....	90
Tabulka 12 - Kalkulace nákladů dle navrženého modelu	92
Tabulka 13 - Hodnoty MSE pro ověření navrženého modelu NN pro jiný typ zboží	95

Seznam příloh

Příloha 1: Životopis

Příloha 2: Seznam publikační činnosti

Životopis

1. Osobní informace

Jméno: Ing. Tereza Šustrová
Rodné příjmení: Varyšová
Datum narození: 5. prosince 1986
Místo narození: Ostrava - Vítkovice
Bydliště: Nadační 581/1, 621 00 Brno
E-mail: tereza.varysova@gmail.com
Telefon: +420 776 808 373

2. Vzdělání

- 2011 - dosud:** Fakulta podnikatelská, VUT v Brně, doktorský studijní program Ekonomika a management, studijní obor **Řízení a ekonomika podniku**. Téma dizertační práce: Využití Soft Computingu v rámci řízení objednávkového cyklu, školitel: prof. Ing. Petr Dostál, CSc., Ústav informatiky.
- 2010 - 2012:** Fakulta podnikatelská, VUT v Brně, navazující magisterský studijní program Systémové inženýrství a informatika, studijní obor **Informační management**, udělen titul Ing.
- 2009 - 2011:** Fakulta podnikatelská, VUT v Brně, navazující magisterský studijní program Ekonomika a management, studijní obor **Podnikové finance a obchod**, udělen titul Ing.
- 2007 - 2010:** Fakulta podnikatelská, VUT v Brně, bakalářský studijní program Systémové inženýrství a informatika, studijní obor **Manažerská informatika**, udělen titul Bc.
- 2006 - 2009:** Fakulta podnikatelská, VUT v Brně, bakalářský studijní program Ekonomika a management, studijní obor **Daňové poradenství**, udělen titul Bc.
- 1998 – 2006:** **Gymnázium Mikuláše Koperníka** v Bílovci.

3. Pedagogická praxe

- 2015/2016** Předmět Matematika II, vedení cvičení v LS, obor Ekonomika a procesní management a Účetnictví a daně, Fakulta podnikatelská, VUT v Brně.
- Předmět Statistika, vedení cvičení v ZS, obory Ekonomika a procesní management a Účetnictví a daně, Fakulta podnikatelská, VUT v Brně.
- Vedení 4 bakalářských prací.
- 2014/2015** Předmět Matematika II, vedení cvičení v LS, obor Ekonomika a procesní management, Fakulta podnikatelská, VUT v Brně.
- Předmět Matematika I, vedení cvičení v ZS, obor Ekonomika a procesní management, Fakulta podnikatelská, VUT v Brně.
- Předmět Statistika, vedení cvičení v ZS, obory Ekonomika a procesní management a Účetnictví a daně, Fakulta podnikatelská, VUT v Brně.
- Vedení 2 bakalářských prací.
- 2013/2014** Předmět Matematika II, vedení cvičení v LS, obor Manažerská informatika, Fakulta podnikatelská, VUT v Brně.
- Předmět Matematika I, vedení cvičení v ZS, obor Manažerská informatika, Fakulta podnikatelská, VUT v Brně.
- 2012/2013** Předmět Matematika II, vedení cvičení v LS, obor Manažerská informatika, Fakulta podnikatelská, VUT v Brně.
- Předmět Pokročilé metody analýz a modelování, vedení cvičení v LS, obory Řízení a ekonomika podniku, Podnikové finance a obchod, Účetnictví a finanční řízení podniku, Fakulta podnikatelská, VUT v Brně.

Předmět Algoritmizace a programovací techniky, vedení cvičení v ZS, obor Manažerská informatika, Fakulta podnikatelská, VUT v Brně.

Předmět Informatika pro Ekonomy, vedení cvičení v ZS, obory Daňové poradenství a Ekonomika podniku, Fakulta podnikatelská, VUT v Brně.

2011/2012 Předmět Informatika pro Ekonomy, vedení cvičení v ZS, obory Daňové poradenství a Ekonomika podniku, Fakulta podnikatelská, VUT v Brně.

4. Řešené projekty

2015/2016 Efektivní využití ICT a kvantitativních metod pro optimalizaci podnikových procesů, zahájení: 01.01.2015, ukončení: 31.12.2016.

2013/2014 Využití ICT a matematických metod při řízení podniku; zahájení: 01.01.2013, ukončení: 31.12.2014.

2012 Efektivní ekonomické řízení podniku s ohledem na vývoj globálních trhů; zahájení: 01.01.2012, ukončení: 31.12.2012.

5. Další aktivity na akademické půdě

Aktivní účast na mezinárodních konferencích a workshopech:

2015 15th International Conference at Brno University of Technology, Faculty of Business and Management, Brno.

2014 4rd Annual Scientific Conference, "Practice and Research in Private and Public Sector 2014", Vilnius, Litva.

2013 3rd Annual Scientific Conference, "Practice and Research in Private and Public Sector 2013", Vilnius, Litva.

2011 - 2012 International Workshop for Ph.D. students.

Člen organizačního výboru mezinárodních workshopů a událostí:

2016 The 27th IBIMA conference on Innovation Management and Education Excellence: From Regional Development Sustainability to Global Economic Growth, Milan, Italy 4-5 May 2016, conference program committee.

2015 The 26th IBIMA conference on Innovation Management and Sustainable Economic Competitive Advantage: From Regional Development to Global Growth, Madrid, Spain 11-12 November 2015, conference program committee.

2014 The 24th IBIMA conference on Crafting Global Competitive Economies: 2020 Vision Strategic Planning & Smart Implementation, Milan, Italy 6-7 November 2014, conference program committee.

Člen volební komise pro volby do akademického senátu FP VUT a akademického senátu VUT.

2012-2015 Business Point / Business Point Workshop.

2011 - 2012 International Workshop for Ph.D. students.

Zahraniční pobyty v rámci programu Free Mover:

2014 Fakulta hospodárskej informatiky, Ekonomická univerzita v Bratislave, Bratislava, Slovensko, 31 dní, náplň pobytu: analýza dat k dizertační práci.

2013 Faculty of Business and Law, Leeds Metropolitan University, Leeds, Spojené království Velké Británie a Severního Irska, 30 dní, náplň pobytu: literární rešerše k pojednání k dizertační práci.

2012 Nottingham Trent University, Nottingham, Spojené království Velké Británie a Severního Irska, 9 dní, náplň pobytu: literární rešerše k dizertační práci.

6. Absolvované odborné kurzy

- 2014** Doplňující pedagogické studium pro akademické pracovníky na VUT v Brně.
- 2006** vítěz celostátního kola soutěže Banks in Action pořádané Junior Achievement Czech Republic.
- 2005/2006** Kurz aplikované ekonomie zastřešovaný organizací Junior Achievement Czech Republic.

7. Pracovní zkušenosti

- 2014 – dosud:** Konzultant informačních systémů Microsoft Dynamics.
- 2011 – dosud:** Vedení účetnictví a daňové evidence, konzultace v oblasti daní.
- 2009 – 2014:** Vývoj webových stránek v jazyce PHP a HTML a CSS.
- 2005 – 2013:** Kopírovací centrum v Novém Jičíně, obsluha zákazníků.

8. Jazykové znalosti

Anglický jazyk: plyně.

2009 získání certifikátu anglického jazyka TOEFL ITP na úrovni B2.

Německý jazyk mírně pokročilý.

Ruský jazyk začátečník.

9. Další zájmy a dovednosti

Silniční cyklistika, běh, squash, běh na lyžích, hudba.

Řidičský průkaz skupiny B.

Seznam publikační činnosti

Celkový počet publikací: 15

Článek v časopise s IF

NOVOTNÁ, V.; ŠUSTROVÁ, T. Solving Macroeconomic Model Using Methods of Functional Analysis. *Economic Computation and Economic Cybernetics Studies and Research*, 2015, roč. 2015, č. 3, s. 253-266. ISSN: 0424- 267X.

Článek v recenzovaném časopise zahrnutém do databáze SCOPUS

NOVOTNÁ, V.; VARYŠOVÁ, T.; JANKOVÁ, M. FUNCTIONS OF SEVERAL VARIABLES ANALYSIS APPLIED IN INVENTORY MANAGEMENT. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 2013, roč. 2013, č. 7, s. 2221-2227. ISSN: 1211- 8516.

Článek v recenzovaném časopise ze seznamu RVVI

VARYŠOVÁ, T. Odvětví informačních a komunikačních technologií v období ekonomické recese: vliv vývoje HDP na zisk a zadluženost firem z oblasti ICT v České republice. *TRENDY EKONOMIKY A MANAGEMENTU*, 2013, roč. 7, č. 15, s. 75-81. ISSN: 1802- 8527.

Příspěvky v recenzovaném sborníku z mezinárodní konference evidovaný v databázi společností Thomson Reuters

NOVOTNÁ, V.; VARYŠOVÁ, T. The Application of Functions of Several Variables Analysis in an Optimal Replenishment Policy for Deteriorating Items. In *2ND GLOBAL CONFERENCE ON BUSINESS, ECONOMICS, MANAGEMENT AND TOURISM. Procedia Economics and Finance*. London: Elsevier, 2015. s. 1217-1226. ISSN: 2212- 5671.

VARYŠOVÁ, T. Time Series Forecasting Using Artificial Neural Network. In *Proceedings of the 25th International Business Information Management Association Conference*. Amsterdam: International Business Information Management Association (IBIMA), 2015. s. 527-535. ISBN: 978-0-9860419-4- 5.

NOVOTNÁ, V.; VARYŠOVÁ, T. Solving of Economic Model Using Modern Methods. In *Vision 2020: Sustainable Growth, Economic Development, and Global Competitiveness*. - Valencia: IBIMA, 2014. s. 1811-1821. ISBN: 978-0-9860419-2- 1.

NOVOTNÁ, V.; VARYŠOVÁ, T. Impact analysis of changes in parameters on profit in inventory management. In *The 22nd International Business Information Management Association Conference*. IBIMA. Rome, Italy: IBIMA, 2013. s. 1361-1369. ISBN: 978-0-9860419-1- 4.

Článek v odborném recenzovaném časopise

NOVOTNÁ, V.; ŠUSTROVÁ, T. *Solution of Dynamical Macroeconomic Model Using Modern Methods*. Journal of Eastern Europe Research in Business & Economics. USA: IBIMA Publishing library, 2015. s. 1-9. ISSN: 2169-0367.

Příspěvky na ostatních mezinárodních konferencích a workshopech

ŠUSTROVÁ, T. Suitable Models for Seasonal and Trend Time Series Forecasting. In *Perspectives of Business and Entrepreneurship Development*. 1. Brno: Faculty of Business and Management, Brno University of Technology, 2015, 2015. s. 422-429. ISBN: 978-80-214-5227- 5.

VARYŠOVÁ, T. Application of Soft Computing Methods in Inventory Management. *1st international scientific conference "Practice and research in private public sector-11"*, 2014, roč. 14, č. 4, s. 200-206. ISSN: 2029- 7378.

VARYŠOVÁ, T. Výběr finančních ukazatelů pro model hodnocení bonity firmy. In *Mezinárodní workshop doktorandských prací*. Brno: FP, VUT Brno, 2012. s. 1-6. ISBN: 978-80-214-4632- 8.

KUTAL, J.; VARYŠOVÁ, T. Možnosti využití umělé inteligence v optimalizaci pro vyhledávače. In *Mezinárodní workshop doktorandských prací*. Brno: Fakulta podnikatelská, 2011. s. 1-6. ISBN: 978-80-214-4348- 8.

Přijaté zatím nepublikované příspěvky

NOVOTNÁ, V.; ŠUSTROVÁ, T. Order Management System Proposal Using Inventory Balance Equation With Non-continuous Replenishment. *Periodica Polytechnica Social and Management Sciences* (SCOPUS)

ŠUSTROVÁ, T. A Suitable Artificial Intelligence Model for Inventory Level Optimization. *Trends Economics and Management*. (RVVI)

Příspěvky v recenzním řízení

ŠUSTROVÁ, T. An Artificial Neural Network Model for the Wholesale Company Order's Cycle Management. *Journal of Engineering Business Management*. (SCOPUS, Thomson Reuters)