

**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

**FAKULTA PODNIKATELSKÁ**

Ústav informatiky

**Ing. Tereza Šustrová**

**VYUŽITÍ SOFT COMPUTINGU V RÁMCI ŘÍZENÍ  
OBJEDNÁVKOVÉHO CYKLU**

**THE UTILIZATION OF SOFT COMPUTING  
IN ORDERING CYCLE MANAGEMENT**

Zkrácená verze PhD Thesis

Obor: Řízení a ekonomika podniku

Školitel: prof. Ing. Petr Dostál, CSc.

## **KLÍČOVÁ SLOVA**

Objednávkový cyklus podniku, Soft Computing, umělé neuronové sítě, řízení dodavatelského řetězce, řízení zásob, velikost objednávky.

## **KEYWORDS**

Company's Ordering Cycle, Soft Computing, Artificial Neural Networks, Supply Chain Management, Inventory Management, Lot-Sizing Problem

## **MÍSTO ULOŽENÍ PRÁCE**

Vysoké učení technické v Brně

Fakulta podnikatelská

Oddělení pro vědu a výzkum

Kolejní 2906/4

612 00 Brno

Knihovna FP VUT v Brně

# Obsah

Úvod.....	4
1 Cíle dizertační práce.....	5
2 Metodologie zpracování dizertační práce .....	6
2.1 Metody vědeckého zkoumání.....	6
2.2 Model a modelování.....	7
2.3 Umělé neuronové sítě.....	8
2.4 Metody analýzy dat .....	8
2.4.1 Analýza časových řad.....	8
2.4.2 Přístupy k modelování časových řad.....	9
3 Zhodnocení současného stavu řešené problematiky .....	11
3.1 Řízení dodavatelského řetězce .....	11
3.1.1 Procesní pohled na dodavatelský řetězec .....	11
3.1.2 Vývojové typy dodavatelského řetězce.....	11
3.2 Řízení zásob v obchodě.....	12
3.3 Současné trendy modelů pro řízení zásob .....	14
3.4 Současné trendy v predikci časových řad pomocí Soft Computingu.....	14
3.5 Soft Computing při řízení zásob.....	16
3.5.1 Fuzzy logika a další pokročilé metody rozhodování.....	16
4 Výsledky dizertační práce .....	20
4.1 Popis aktuálního stavu analyzované společnosti.....	20
4.2 Umělá neuronová síť pro predikci prodeje.....	21
4.2.1 Predikce prostřednictvím umělých neuronových sítí .....	21
4.2.2 Srovnání modelu umělé neuronové sítě a statistických metod.....	22
4.3 Neuronová síť pro řízení zásob .....	22
4.3.1 Proměnné modelu umělé neuronové sítě.....	22
4.3.2 Architektura modelu umělé neuronové sítě.....	23
4.3.3 Výsledky modelu neuronové sítě .....	24
4.4 Model řízení objednávkového cyklu .....	24
4.4.1 Ověření použitelnosti modelu řízení objednávkového cyklu .....	25
4.5 Metodika pro využití navrženého modelu.....	26
5 Přínosy dizertační práce .....	27
5.1 Teoretická oblast .....	27
5.2 Praktická oblast .....	27
5.3 Pedagogická oblast.....	28
6 Závěr .....	29
7 Seznam použitých zdrojů .....	30

## 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

**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.

### 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 analytickou-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 vyslovená hypotéza je schopna 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 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 Umělé neuronové sítě**

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)

Umělé neuronové sítě 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)

### **2.4 Metody analýzy dat**

#### *2.4.1 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.

#### 2.4.2 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 ( $\varepsilon_t$ ).

- *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  $y_t$ :

$$y_t = T_t + S_t + C_t + \varepsilon_t \quad (1)$$

- *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.

$$y_t = T_t * S_t * C_t * \varepsilon_t \quad (2)$$

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

$$\ln(y_t) = \ln(T_t) + \ln(S_t) + \ln(C_t) + \ln(\varepsilon_t) \quad (3)$$

(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)

### *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)

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)

### 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. (Křižko, 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 zákaznickova požadavku. V širším smyslu znamená dodavatelský řetězec dvě a více právně samostatných firem propojené 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 splnili 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)

Každý cyklus se skládá ze šesti subprocesů, 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)

##### 3.1.2 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 přerušení toku prakticky ve všech člancích 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 kompletačí a konsolidací, ze zákazníků a dodavatelů. Tok materiálu je zcela plynulý, bez přerušení 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 Řízení zásob v obchodě**

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, 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)

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, nekvalitní servis či neschopnost 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.

### 3.3 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 Seannan, 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)

### 3.4 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.

### **3.5 Soft Computing při řízení zásob**

#### *3.5.1 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 objednací 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 objednávkou 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.

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 Choueikho (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 sestrojít 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 maloobchodníkům, 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 nízko, 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 Umělá neuronová síť pro predikci prodeje

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

Jako vstup pro model umělé neuronové sítě je využita časová řada skládající se ze 72 měsíčních údajů o prodejích. Existují 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.

Pro trénování neuronové sítě je použit algoritmus Levenberg-Marquardt backpropagation, 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. Vzhledem k průměrným hodnotám MSE je nejlepší varianta 70 % vzorku pro testování, 15 % vzorku pro validaci a 15 % vzorku pro testování.

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.

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

#### 4.2.2 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 a pomocí statistických metod, konkrétně prostřednictvím ARIMA modelu.

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.

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. 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.

### 4.3 Neuronová síť pro řízení zásob

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.

#### 4.3.1 Proměnné modelu umělé neuronové sítě

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

Jako vstupní parametry jsou použity proměnné:

- aktuální měsíční poptávky – což je poptávka po daném typu zboží v měsíci, kdy je zboží objednáváno;
- poptávky v příštích třech měsících taktéž po konkrétním typu zboží, tento ukazatel je důležitý pro odhad úrovně zásob v době dodání objednaného zboží;
- poptávky 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. Převážnými 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.

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.

#### 4.3.2 *Architektura modelu umělé neuronové sítě*

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  $(0,1)$  pro získání standardizovaných hodnot pro využití umělé neuronové sítě.

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.

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, může být použit pro aplikace, například pro rozpoznávání vzorů, shlukování, predikce časových řad či modelování a řízení dynamických systémů. (Beale a kol., 2015)

Je použit model umělé neuronové sítě typu „Feed-forward backpropagation“ 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 2 a to TRAINGDX a TRAINSCG, jako funkce pro učení byla použita LEARNGDM, přenosová funkce byla použita jak TANSIG tak LOGSIG. Maximální počet trénovacích epoch byl stanoven na 1 000, maximální počet validačních kontrol byl stanoven taktéž na 1 000.

Trénování umělé neuronové sítě je prováděno pomocí 24 vzorků dat obsahující 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. Hodnota koeficientu determinace se pohybuje v intervalu  $\langle 0,1 \rangle$ , přičemž cílem je určit přesnost následně predikovaných dat. Čím blíže 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, o to menší rozdíl se jedná, nula znamená žádnou chybu.

#### 4.3.3 Výsledky modelu neuronové sítě

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 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.

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.

#### 4.4 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 3 měsíčním intervalu pro dodání zboží. Zatím však nebylo řečeno, kdy by měla být objednávka provedena.

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 nespécifikovaných 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 objednáno 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.

#### *4.4.1 Ověření použitelnosti modelu řízení objednávkového cyklu*

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.

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.

#### 4.5 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.

### 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 Azeem (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.

### 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.

Navržené modely lze využít buď po částech, nebo dohromady. Manažeři obchodních společností jistě ocení možnost predikce prodejů, a to především v případě prodejů 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 3 měsících a poptávku ve 3 měsících následujících po 3 měsíčním objednávkovém cyklu, lze samozřejmě přizpůsobit dle délky objednávkového cyklu kteréhokoliv podniku a zkonstruovanou neuronovou síť 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.

První část dizertační práce byla věnována 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. 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.

## 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 0 (mn)-Algorithm for Structured Problems. *Operations Research*. 1993. Vol. 41, no. 3, pp. 155-180. DOI: [http://dx.doi.org/10.1007/springerreference\\_6865](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) 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.
- 6) 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](http://www.intechopen.com/journals/international_journal_of_engineering_business_management/lot-sizing-heuristics-performance)
- 7) BEALE, M. H., M. T. HAGAN, H. B. DEMUTH. MATHWORKS. *Neural Network Toolbox: User's guide*. Natick, MA, 2015.
- 8) 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>
- 9) BOX, G. E., JENKINS, G. M. Time series analysis: Forecasting and control. In *Holden-Day series in time series analysis*. Holden-Day. 1976.
- 10) 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>.
- 11) 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.
- 12) DOSTÁL, P., *Soft computing v podnikatelství a veřejné správě: Díl I.*, Vydání první. Brno: Akademické nakladatelství CERM, 2015.
- 13) 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](http://dx.doi.org/10.1007/978-3-658-02089-7_7).
- 14) 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>.

- 15) 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>.
- 16) 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>.
- 17) FÁBRY, Jan. *Matematické modelování*. 1. vyd. Praha: Professional Publishing, 2011. 180 s. ISBN 978-80-7431-066-9.
- 18) 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>
- 19) 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>
- 20) GAAFAR, L. K., CHOUËIKI, 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).
- 21) 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).
- 22) HACHICHA, W. A simulation metamodeling 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](http://www.ijssimm.com/Full_Papers/Fulltext2011/text10-4_191-203.pdf).
- 23) HAMZAÇEBI, C. Improving artificial neural networks' performance in seasonal time series forecasting. *Information Sciences*. 2008. Vol. 178, no. 23, pp. 4550-4559.
- 24) 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.
- 25) 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.
- 26) 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,
- 27) HILL, T., O'CONNOR, M., REMUS, W. Neural network models for time series forecasts. *Management science*. 1996. Vol. 42, no. 7, pp. 1082-1092.
- 28) HOŘEJŠÍ, B. et al. *Mikroekonomie*. 5., aktualiz. vyd. Praha: Management Press. 2010. 574 s. ISBN 978-80-7261-218-5.
- 29) 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.
- 30) 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>.
- 31) 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.
  - 32) 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.
  - 33) 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>
  - 34) 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>.
  - 35) 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.
  - 36) 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>.
  - 37) MULAČOVÁ, V., P. MULAČ. *Obchodní podnikání ve 21. století*. 1. vyd. Praha: Grada, 2013. ISBN 978-80-247-4780-4.
  - 38) 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.
  - 39) 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](http://web.fame.utb.cz/cs/docs/Z_klady_v_deck_pr_ce.doc).
  - 40) 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>.
  - 41) 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.
  - 42) 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>.
  - 43) 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.

- 44) 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>.
- 45) PERNICA, P. *Logistika pro 21. století: (Supply chain management)*. Vyd. 1. Praha: Radix, 2005. ISBN 80-860-3159-4.
- 46) 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.
- 47) 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>.
- 48) 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>.
- 49) 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>.
- 50) 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>.
- 51) ŞENYİĞİT, 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>.
- 52) 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.
- 53) 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>.
- 54) 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>.
- 55) SEGER, J., HINDLS, R. *Statistické metody v tržním hospodářství*. 1.vyd. Praha: Victoria Publishing, 1995, 435 s. ISBN 80-7187-058-7.
- 56) 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.

- 57) 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>.
- 58) 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.
- 59) 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>.
- 60) 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](http://www.mvso.cz/Files/WEB/APSYS/72Publikovani_a_presentace_vysledku_VaV.pdf).
- 61) 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.
- 62) 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>.
- 63) 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>.
- 64) 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>.
- 65) ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 2003. Vol. 50, pp. 159-175.
- 66) 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>.
- 67) 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.
- 68) ZHANG, T. A Monte Carlo Analysis for Stochastic Distance Function Frontier. *Inzinerine Ekonomika-Engineering Economics*. 2012. Vol. 23, no. 3, pp. 250-255.
- 69) 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](http://dx.doi.org/10.1007/springerreference_6988).

# Životopis

## 1. Osobní informace

Jméno: Tereza Šustrová  
Rodné příjmení: Varyšová  
Narození: 5. prosince 1986, Ostrava  
Bydliště: Nadační 581/1, 621 00 Brno  
E-mail: tereza.varysova@gmail.com

## 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

Informatika pro Ekonomy, Algoritmizace a programovací techniky, Pokročilé metody analýz a modelování, Matematika I, Matematika II, Statistika

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

Člen organizačního výboru mezinárodních workshopů a událostí:

- 2016** The 27<sup>th</sup> 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 26<sup>th</sup> 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 24<sup>th</sup> IBIMA conference on Crafting Global Competitive Economies: 2020 Vision Strategic Planning & Smart Implementation, Milan, Italy 6-7 November 2014, conference program committee
- 2012-2015** Business Point / Business Point Workshop
- 2012** International Workshop for Ph.D. students
- 2011** 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: plynně.

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.

## **Strukturovaný přehled 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. An Artificial Neural Network Model for the Wholesale Company Order's Cycle Management. *Journal of Engineering Business Management*. (SCOPUS, Thomson Reuters)

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

### **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.