

Využití soft computingových metod v podnikové ekonomice

Radka Míšková

Bakalářská práce
2025



Univerzita Tomáše Bati ve Zlíně
Fakulta managementu a ekonomiky

Univerzita Tomáše Bati ve Zlíně

Fakulta managementu a ekonomiky

Ústav podnikové ekonomiky

Akademický rok: 2024/2025

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Radka Míšková
Osobní číslo:	M21848
Studijní program:	B0413A050024 Ekonomika a management
Specializace:	Ekonomika a management podniku
Forma studia:	Kombinovaná
Téma práce:	Využití soft computingových metod v podnikové ekonomice

Zásady pro vypracování

Úvod

Definujte cíle práce a použité metody zpracování práce.

I. Teoretická část

- Proveďte průzkum literárních pramenů a vypracujte literární rešerši zaměřenou na soft computingové metody a jejich využití v podnikové ekonomice.

II. Praktická část

- Analyzujte jednotlivé možnosti využití soft computingových metod v oblasti podnikové ekonomiky.
- Na základě předchozích analýz vypracujte případové studie a prezentujte jednotlivé možnosti využití soft computingových metod v oblasti podnikové ekonomiky.

Závěr

Rozsah bakalářské práce: cca 40 stran
Forma zpracování bakalářské práce: tištěná/elektronická

Seznam doporučené literatury:

DOSTÁL, Petr. *Soft computing v podnikatelství a veřejné správě*. Brno: Akademické nakladatelství CERM, 2015. ISBN 9788072048960.
FABOZZI, Frank J. *Capital markets: institutions, instruments, and risk management*. Fifth edition. Cambridge, Massachusetts: London, 2015. ISBN 978-0-262-02948-3.
MANKIW, N. Gregory a TAYLOR, Mark P. *Economics*. Sixth edition. Hampshire: Cengage, 2023. ISBN 978-1-4737-8698-1.
MARTINOVIČOVÁ, Dana; KONEČNÝ, Miloš a VAVŘINA, Jan. *Úvod do podnikové ekonomiky*. 2., aktualizované vydání. Praha: Grada, 2019. ISBN 978-80-271-2034-5.
REJNUŠ, Oldřich. *Finanční trhy*. 5. aktualizované a rozšířené vydání. Praha: Grada, 2024. ISBN 978-80-271-5012-0.

Vedoucí bakalářské práce: Ing. et Ing. Vojtěch Sadil, PhD. LL.M.
Ústav financí a účetnictví

Datum zadání bakalářské práce: 10. února 2025
Termín odevzdání bakalářské práce: 23. května 2025

L.S.

doc. Ing. Michal Pilík, Ph.D.
děkan

doc. Ing. Petr Novák, Ph.D.
garant studijního programu

Ve Zlíně dne 10. února 2025

PROHLÁŠENÍ AUTORA BAKALÁŘSKÉ PRÁCE

Beru na vědomí, že

- odevzdáním bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb., v platném znění bez ohledu na výsledek obhajoby;
- bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému a bude dostupná k nahlédnutí;
- jedno vyhotovení bakalářské práce v listinné podobě bude ponecháno Univerzitě Tomáše Bati ve Zlíně k uložení;
- na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- podle § 60 odst. 1 autorského zákona má Univerzita Tomáše Bati ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- podle § 60 odst. 2 a 3 mohu užít své dílo – bakalářskou práci – nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- pokud bylo k vypracování bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tj. k nekomerčnímu využití), nelze výsledky bakalářské práce využít ke komerčním účelům;
- pokud je výstupem bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá; neodevzdání této součásti může být důvodem k neobhájení práce.

Prohlašuji, že

- jsem na bakalářské práci pracoval(a) samostatně a použitou literaturu jsem řádně citoval(a); v případě publikace výsledků budu uveden(a) jako spoluautor;
- odevzdaná verze bakalářské práce a verze elektronická nahraná do IS/STAG jsou obsahově totožné.

Ve Zlíně, dne

.....

podpis autora

Prohlašuji, že při zpracování této bakalářské práce jsem využila nástroj generativního jazykového modelu ChatGPT (chat.openai.com), a to výhradně za účelem stylistické úpravy odborného textu a při tvorbě případové studie zaměřené na využití neuronové sítě pro predikci spotřeby materiálu. Veškerý takto vygenerovaný obsah byl mnou následně zkontrolován, upraven a přizpůsoben, přičemž za jeho finální podobu a správnost nesu plnou odpovědnost.

ABSTRAKT

Tato bakalářská práce se zabývá využitím soft computingových metod v oblasti podnikové ekonomiky. Cílem práce je analyzovat, jak lze metody jako fuzzy logika, umělé neuronové sítě, genetické a evoluční algoritmy aplikovat na řešení problémů v podnikové praxi, zejména v oblastech rozhodování, predikce, optimalizace a hodnocení. Teoretická část práce se věnuje vysvětlení základních pojmů podnikové ekonomiky a detailnímu popisu vybraných soft computingových metod. V praktické části jsou shrnuty možnosti využití soft computingových metod. Dále jsou vytvořeny případové studie s využitím nástrojů jako Microsoft Excel a umělá inteligence, které ukazují konkrétní využití těchto metod pro podporu manažerského rozhodování a hodnocení finančního zdraví firem.

Klíčová slova: podnik, řízení podniku, soft computing, fuzzy logika, neuronové sítě

ABSTRACT

This bachelor thesis deals with the use of soft computing methods in the field of business economics. The aim of the thesis is to analyze how methods such as fuzzy logic, artificial neural networks, genetic and evolutionary algorithms can be applied to solve problems in business practice, especially in the areas of decision making, prediction, optimization, and evaluation. The theoretical part of the thesis is devoted to explaining the basic concepts of business economics and a detailed description of selected soft computing methods. In the practical part the possibilities of using soft computing methods are summarized. Furthermore, the case studies using tools such as Microsoft Excel and artificial Intelligence, which show the concrete use of these methods to support managerial decision-making and assessing the financial health of companies.

Keywords: the company, corporate governance, soft computing, fuzzy logic, neural networks

Na tomto místě bych chtěla poděkovat panu Vojtěchu Sadilovi za odborné vedení, cenné rady a podnětné připomínky, které mi pomohly při zpracování této bakalářské práce. Mé poděkování patří také mé rodině za jejich podporu, trpělivost a povzbuzení po celou dobu studia.

„Skutečné problémy neznají ostré hranice.“

Lofti A. Zadeh (zakladatel fuzzy logiky)

OBSAH

ÚVOD.....	11
CÍLE A METODY ZPRACOVÁNÍ PRÁCE.....	12
I TEORETICKÁ ČÁST.....	13
1 PODNIKOVÁ EKONOMIKA.....	14
1.1 DRUHY PODNIKŮ.....	14
1.1.1 Podle právní subjektivity.....	15
1.1.2 Podle velikosti.....	17
1.2 HOSPODAŘENÍ PODNIKU.....	17
1.2.1 Majetková struktura podniku.....	18
1.2.2 Finanční struktura podniku.....	19
1.2.3 Náklady, výnosy a výsledek hospodaření.....	19
1.2.4 Finanční analýza.....	20
1.3 OKOLÍ PODNIKU.....	21
1.3.1 Finanční trh.....	21
2 ŘÍZENÍ PODNIKU.....	23
2.1 PODSTATA MANAGEMENTU.....	23
2.2 MANAŽERSKÉ ROZHODOVÁNÍ.....	24
2.2.1 Manažerský proces.....	24
2.2.2 Plánování.....	25
2.2.3 Organizování.....	25
2.3 PODNIK A RIZIKO.....	26
2.3.1 Klasifikace rizik.....	27
2.3.2 Řízení rizika.....	28
2.4 FINANČNÍ ŘÍZENÍ PODNIKU.....	28
3 SOFT COMPUTING.....	30
3.1 ÚVOD.....	30
3.1.1 Podstata.....	30
3.1.2 Historie.....	31
3.1.3 Pojmy.....	31
3.2 METODY.....	33
3.2.1 Fuzzy logika.....	33
3.2.2 Umělé neuronové sítě.....	36
3.2.3 Teorie chaosu.....	39
3.2.4 Genetické algoritmy.....	41
3.2.5 Shrnutí dalších soft computingových metod.....	42
4 SHRUTÍ TEORETICKÉ ČÁSTI.....	44

II	PRAKTICKÁ ČÁST	46
5	ANALÝZA MOŽNOSTÍ VYUŽITÍ SOFT COMPUTINGOVÝCH METOD	47
5.1	VYUŽITÍ FUZZY LOGIKY V PODNIKOVÉ EKONOMICE	47
5.2	VYUŽITÍ NEURONOVÝCH SÍTÍ V PODNIKOVÉ EKONOMICE	49
5.3	VYUŽITÍ TEORIE CHAOSU	52
5.4	MOŽNOSTI VYUŽITÍ DALŠÍCH SOFT COMPUTINGOVÝCH METOD	53
6	MODEL FUZZY LOGIKY PRO HODNOCENÍ FINANČNÍHO ZDRAVÍ PODNIKŮ	55
7	NÁVRH MODELU NEURONOVÉ SÍTĚ PRO PREDIKCI SPOTŘEBY MATERIÁLU	64
7.1	ÚVOD, POPIS PROBLÉMU A CÍL	64
7.2	OBEČNÝ NÁVRH ARCHITEKTURY MODELU NEURONOVÉ SÍTĚ	64
7.3	OBEČNÝ POSTUP ŘEŠENÍ	66
7.4	POUŽITÁ METODIKA A POPIS KONKRÉTNÍHO MODELU V R – PŘÍKLAD TŘÍ SUROVIN	67
7.5	POSTUP ŘEŠENÍ PRO KONKRÉTNÍ PŘÍKLAD	68
7.6	ZÁVĚR	71
8	SHRNUTÍ PRAKTICKÉ ČÁSTI.....	72
	ZÁVĚR.....	73
	SEZNAM POUŽITÉ LITERATURY	75
	SEZNAM OBRÁZKŮ	79
	SEZNAM TABULEK.....	80
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	81
	SEZNAM PŘÍLOH.....	82

ÚVOD

Současné podnikové prostředí se neustále mění a stává se čím dál složitějším. Firmy se musí umět rychle přizpůsobit novým podmínkám a zároveň efektivně pracovat s daty, která bývají často neúplná nebo neurčitá. Tradiční analytické metody v takových situacích ale často nestačí. Právě proto se v posledních letech dostávají do popředí alternativní přístupy, které jsou flexibilnější a lépe zvládají práci s nepřesnými daty. Jedním z nich je tzv. soft computing.

Soft computing zahrnuje soubor výpočetních technik, které umožňují řešit složité úlohy i tehdy, když nemáme k dispozici přesné a jednoznačné vstupy. Patří sem například fuzzy logika, umělé neuronové sítě nebo evoluční algoritmy. Tyto metody se inspirovaly přírodními jevy nebo způsobem lidského myšlení. V poslední době se čím dál častěji uplatňují i v podnikové ekonomice – třeba při odhadu ekonomických ukazatelů, hodnocení investic nebo při řízení podnikových rizik.

Cílem této bakalářské práce je prozkoumat možnosti metod soft computingu v podnikovém prostředí a ukázat jejich praktické využití na konkrétních příkladech. V teoretické části se nejdříve zaměřím na vysvětlení základních pojmů z oblasti podnikové ekonomiky a následně popíšu vybrané soft computingové metody. Praktická část bude věnována analýze konkrétních možností jejich využití, a to za pomoci odborné literatury a závěrečných prací. Také budou vytvořeny případové studie, které budou demonstrovat konkrétní možnosti využití soft computingových metod za pomoci programu Microsoft Excel a umělé inteligence.

Vzhledem k tomu, že význam datové analýzy a umělé inteligence v ekonomice neustále roste, věřím, že se jedná o aktuální a prakticky využitelné téma.

Umělá inteligence byla konkrétně využita k opravě a stylistické úpravě textu s cílem zvýšit jeho jazykovou kvalitu, srozumitelnost a odbornou úroveň. A také pro generování návrhu případových studií.

CÍLE A METODY ZPRACOVÁNÍ PRÁCE

Cílem této bakalářské práce je analyzovat možnosti využití soft computingových metod v oblasti podnikové ekonomiky a na základě těchto poznatků vytvořit případové studie, které prakticky demonstrují aplikaci těchto metod.

Práce je rozdělena na teoretickou a praktickou část. V teoretické části je použita metoda literární rešerše. Při jejím zpracování byla využita odborná literatura českých i zahraničních autorů, články z odborných časopisů a další veřejně dostupné zdroje. Teoretická část se zaměřuje na klíčové pojmy z oblasti podnikové ekonomiky, řízení podniku, soft computing a jeho jednotlivé metody. Cílem této části bylo vytvořit teoretický základ pro navazující praktickou část.

V praktické části je provedena analýza možností využití soft computingových metod v podnikovém prostředí. Tato analýza je postavena na informacích z odborné literatury, bakalářských a diplomových prací. Následně byly vytvořeny případové studie, které modelují řešení vybraných problémů pomocí soft computingových metod. Ke zpracování těchto studií byl použit program Microsoft Excel a umělá inteligence.

I TEORETICKÁ ČÁST

1 PODNIKOVÁ EKONOMIKA

Rozhodování jednotlivců v každodenním životě, například v oblasti spotřeby potravin, oblečení či bydlení, je předmětem zkoumání ekonomie. Podobně jsou analyzována rozhodnutí firem v souvislosti s výrobou a distribucí statků a služeb. Ekonomický systém je utvářen prostřednictvím interakcí domácností a firem na trzích, kde dochází k nákupu a prodeji. (Mankiw, 2023)

Podniková ekonomika je zaměřena na podnik jako instituci, jeho cíle, funkce, životní cyklus, organizační struktury, řízení a specifika jednotlivých typů podniků. (Vochozka a Mulač, 2012)

Podnik je základní jednotkou podnikové ekonomiky. Efektivnost podniku je vyjádřena schopností vyrábět produkty, které uspokojují tržní poptávku, při optimálním využití výrobních faktorů. (Vochozka a Mulač, 2012)

„Podnikání v současné době spočívá v samostatné, soustavné, udržitelné, dlouhodobé výdělečné činnosti na vlastní odpovědnost, usilující o zhodnocování vlastníky investovaného kapitálu k dosažení zisku a maximalizaci tržní hodnoty podniku konkurenceschopným uspokojováním potřeb zákazníků, zaměstnanců a dalších zájmových skupin v měnícím se globálním prostředí.“ (Martinovičová et al., 2019, str. 13)

Podnikatel je považován jako nositel podnikání, přičemž jde o fyzickou nebo právnickou osobu, která je právně samostatná, vlastnický oddělený právní subjekt, jenž vykonává svou činnost vlastním jménem a na svou zodpovědnost. (Bugri a Pribišová, 2017)

Podnik je institucí zřízenou k podnikatelské činnosti, jehož cílem je vyrábět a tržně realizovat produkty a služby pro zákazníky a zároveň uspokojovat potřeby těch, kteří jsou s podnikem spjati. Podnik má svého zakladatele a je tedy vlastněn konkrétní osobou. Jeho primárním účelem je generování zisku. (Martinovičová et al., 2019)

1.1 Druhy podniků

Podniky mohou být podle Bugriho a Pribišové klasifikovány následujícím způsobem:

- podle zaměření a charakteru činnosti (výrobní, obchodní podniky, finanční instituce),
- podle příslušnosti k hospodářským odvětvím,
- podle velikosti a rozsahu činnosti,

- podle právní formy podnikání.

1.1.1 Podle právní subjektivity

Právní formy podnikání lze rozdělit do dvou skupin – podnikatel může působit jako fyzická anebo právnická osoba, což představuje klíčové kritérium pro výběr právní formy. (Bugri a Pribišová, 2017)

Živnost

Podnikání fyzických osob, označované jako živnost, je upraveno zákonem č. 455/1991 Sb. o živnostenském podnikání (živnostenský zákon). (Vochozka a Mulač, 2012)

Fyzická osoba může podnikat na základě živnostenského oprávnění, které je udělováno formou živnostenského listu nebo koncesní listiny, a to v závislosti na druhu živnosti. (Bugri a Pribišová, 2017)

Vochozka a Mulač řadí mezi hlavní výhody podnikání fyzických osob patří velmi nízké náklady na založení, možnost okamžitého zahájení podnikání, snadné založení, přerušení či ukončení činnosti a možnost vedení daňové evidence namísto podvojného účetnictví. Nevýhody tohoto způsobu podnikání spočívají dle Vochozky a Mulače v neomezeném ručení podnikatele za závazky společnosti, vysokých požadavcích na odborné a ekonomické znalosti podnikatele, slabším postavení vůči obchodním partnerům.

Živnosti dělíme na: (Bugri a Pribišová, 2017)

- ohlašovací – provozované na základě ohlášení při splnění podmínek
 - živnost řemeslná
 - živnost vázaná
 - živnost volná
- koncesované – provozované na základě udělené koncese.

Podnikání právnických osob

Oproti fyzické osobě nevzniká právnická osoba automaticky, ale až po splnění zákonných podmínek. Proces vzniku vyžaduje uzavření společenské smlouvy či schválení stanov a podání návrhu na registraci u příslušného rejstříkového soudu. (Vochozka a Mulač, 2012)

Obchodní společnosti jsou členěny na základě zákona o obchodních korporacích na:
(Vochozka a Mulač, 2012)

- osobní obchodní společnosti – veřejná obchodní společnost a komanditní společnost,
- kapitálové obchodní společnosti – společnost s ručením omezeným a akciová společnost.

Základní informace k jednotlivým druhům právních forem jsou shrnuty v následující tabulce.

Tabulka 1 Základní informace o obchodních společnostech (vlastní zpracování dle zákona č.90/2012 Sb. o obchodních společnostech a družstvech)

	<i>Akciová společnost</i>	<i>Společnost s ručením omezeným</i>	<i>Veřejná obchodní společnost</i>	<i>Komanditní společnost</i>
<i>Základní kapitál</i>	2 000 000 Kč/ 80 000 €	1 Kč	Minimální výše není stanovena	Komanditista min. 1 Kč
<i>Počet zakládajících členů</i>	Min. 1 právnická osoba	Min. 1 osoba	Min. 2 osoby	Min. 2 osoby (komanditista, komplementář)
<i>Orgány společnosti</i>	Valná hromada, představenstvo, dozorčí rada, správní rada	Valná hromada, jednatelé, dozorčí rada	Každý společník	Statutární orgán – všichni komplementáři
<i>Ručení členů společnosti</i>	Akcionář neručí za závazky	Společně a nerozdílně do výše souhrnu nesplaceného vkladu	Společně a nerozdílně	Komanditista – omezeně, Komplementář – neomezeně
<i>Označení společnosti</i>	„akc.spol.“ nebo „a.s.“	„Spol.s.r.o.“ nebo „s.r.o.“	„Veř.obch. spol.“ nebo „v.o.s.“,	„Kom.spol.“ nebo „k.s.“

Základní kapitál družstva je vyčíslen ve stanovách. Družstvo může být založeno minimálně třemi členy a při právních úkonech vystupuje pod označením „družstvo“. Orgány družstva, jako jsou členská schůze, představenstvo, kontrolní komise a další, jsou určeny stanovami. Způsob ručení je rovněž vymezen stanovami. (Zákon č.90/2012 Sb., 2012)

Státní podnik je zřízen státem, přičemž funkce zakladatele je vykonávána příslušným ministerstvem podle předmětu podnikání daného podniku. Jejich hlavním účelem je uspokojování celospolečenských, strategických nebo veřejně prospěšných zájmů. Stát za závazky podniku zpravidla neručí, stejně jako podnik neručí za závazky státu. (Martinovičová et al., 2019)

1.1.2 Podle velikosti

Podniky jsou obvykle tříděny podle velikosti do kategorií velkých, středních a malých. Kritéria třídění zahrnují počet zaměstnanců, roční obrat, velikost ročního obrátu na zaměstnance, přidanou hodnotu na zaměstnance, hodnotu majetku či kapitálu, výši ročního zisku či postavení na trhu. (Martinovičová et al., 2019)

Podle Vochozky a Mulač (2012) jsou podniky členěny podle velikosti následovně:

- mikropodniky – méně než 10 zaměstnanců a roční obrat nepřesahující 2 miliony EUR,
- malé podniky – méně než 50 zaměstnanců a roční obrat do 10 milionů EUR,
- střední podniky – méně než 250 zaměstnanců a roční obrat do 50 milionů EUR,
- velké podniky – nad 250 zaměstnanců nebo s ročním obratem nad 50 milionů EUR.

Martinovičová, Konečný a Vavřina (2019) uvádějí, že do kategorie mikropodniků, malých a středních podniků spadají také subjekty, jejichž bilanční suma roční rozvahy nepřesahuje 43 milionů EUR.

1.2 Hospodaření podniku

Rozvaha je základním účetním výkazem každého podniku a poskytuje přehled o struktuře majetku a jeho zdrojích financování. Rozvaha se sestavuje k určitému datu a platí, že aktiva se musí rovnat pasivům. (Knápková et al., 2017)

1.2.1 Majetková struktura podniku

Struktura majetku podniku vyjadřuje podíl jednotlivých složek aktiv na celkovém majetku. Její podoba je obvykle ovlivněna odvětvím a typem podniku, investičních rozhodnutích, efektivitou využití majetku a finanční strategií. (Martinovičová et al., 2019)

Dlouhodobý majetek tvoří část aktiv, která je účetní jednotkou využívána déle než jeden rok a jejíž minimální hodnota je stanovena interními předpisy. Jeho spotřeba neprobíhá najednou, ale postupně prostřednictvím odpisů. Určité druhy dlouhodobého majetku (např. pozemky, umělecká díla, cenné papíry) odepisovány nejsou, neboť nepodléhají fyzickému opotřebení, a jejich hodnota může naopak s časem růst. (Šteker a Otrusinová, 2016)

- Dlouhodobý nehmotný majetek není fyzické povahy a účetní jednotkou je evidován jako soubor práv přinášejících ekonomický prospěch.
- Dlouhodobý hmotný majetek je charakterizován svou fyzickou (hmatatelnou) povahou a účetní jednotce přináší dlouhodobý užitek v rámci její běžné provozní činnosti.
- Dlouhodobý finanční majetek je pořizován účetní jednotka za účelem získání vlivu v jiném podniku, dosažení budoucích výnosů (např. podílů na zisku, úroků) nebo kapitálového zhodnocení.

Oběžná aktiva představují krátkodobý majetek, který se v podniku neustále mění a přechází mezi různými formami. Jejich doba použitelnosti by měla být kratší než 1 rok. Patří sem: zásoby, pohledávky (krátkodobé i dlouhodobé), krátkodobý finanční majetek a peněžní prostředky. Peněžní prostředky zahrnují hotovost v pokladně, zůstatky na bankovních účtech a ceniny. (Knápková et al., 2017)

Klasifikace aktiv v České republice se může lišit od přístupů používaných v zahraničí. Příkladem může být rozdělení aktiv dle Fabozziho, který aktiva definuje jako majetek se směnnou hodnotu. Dělí se na hmotná a nehmotná. Hodnota hmotných aktiv je dána jejich fyzickými vlastnostmi, přičemž mezi příklady lze zařadit budovy, pozemky a stroje. Hmotná aktiva se dále člení na reprodukovatelná aktiva, například stroje, a nereprodukovatelná, mezi něž patří pozemky, doly nebo umělecká díla.

Podle Fabozziho jsou nehmotná aktiva charakterizována jako právní nároky na určitý budoucí užitek. Jejich hodnota nesouvisí s fyzickou podobou, v níž jsou zaznamenány.

Do této kategorie spadají finanční aktiva, finanční nástroje a cenné papíry, pro něž je typický nárok na budoucí peněžní prostředky.

1.2.2 Finanční struktura podniku

Finanční neboli kapitálová struktura podniku je definována jako struktura zdrojů, z nichž je majetek podniku financován. Představuje složení podnikového kapitálu a je zachycena v pasivech rozvahy. Finanční struktura se skládá z vlastního a cizího kapitálu. (Vochozka a Mulač, 2012)

Vlastní kapitál je tvořen vlastními zdroji krytí aktiv účetní jednotky, přičemž je získáván buď od vlastníků (např. prostřednictvím vkladů do základního kapitálu), nebo vlastní činností podniku (např. ziskem po zdanění). (Šteker a Otrusínová, 2016)

Vlastní kapitál zahrnuje základní kapitál, ážio, kapitálové fondy, fondy ze zisku a výsledky hospodaření minulých let i běžného účetního období. (Knápková et al., 2017)

Cizí zdroje představují závazky, které musí být účetní jednotkou uhrazeny v předem stanovené lhůtě. Do cizích zdrojů patří následující základní skupiny:

- Rezervy jsou vytvářeny k pokrytí závazků nebo nákladů účetní jednotky, jejichž existence je k rozvahovému dni pravděpodobná nebo jistá, avšak jejich výše či okamžik jejich vzniku nejsou přesně určeny. (Šteker a Otrusínová, 2016)
- Závazky jsou definovány jako dluh účetní jednotky, tedy povinnost uhradit peníze. Řadí se sem závazky vůči zaměstnancům, institucím (např. sociálního zabezpečení) či společníkům, stejně jako krátkodobé úvěry. (Knápková et al., 2017)

1.2.3 Náklady, výnosy a výsledek hospodaření

Podle Knápkové a kol. jsou výnosy definovány jako peněžní částky, které podnik získal z veškerých svých činností za dané účetní období bez ohledu na to, zda v tomto období došlo k jejich inkasu. Náklady představují peněžní částky účelně vynaložené na dosažení výnosů, i když k jejich skutečnému zaplacení nemuselo ve stejném období dojít.

Výsledek hospodaření podniku je stanoven jako rozdíl mezi celkovými výnosy a celkovými náklady. Zjišťuje se ve dvou složkách – provozní a finanční. Součtem těchto složek je dán výsledek hospodaření před zdaněním, který se následně snižuje o daň z příjmů,

čímž vzniká výsledek hospodaření po zdanění. Výnosy, náklady a výsledek hospodaření tvoří obsah účetního výkazu zisku a ztráty. (Knápková et al., 2017)

Výsledek hospodaření představuje nejvýznamnější vlastní zdroj účetní jednotky vytvořený její vlastní činností a odráží hospodářský výsledek její podnikatelské činnosti za poslední sledované účetní období nebo za období předcházející. (Šteker a Otrusinová, 2016)

Zisk slouží jako ukazatel úspěšnosti podniku nejen vůči vlastníkům a zaměstnancům, ale také vůči obchodním partnerům a konkurenci. Je zároveň nezbytný pro vytváření dalších zdrojů, investic a technický rozvoj. (Vochozka a Mulač, 2012)

1.2.4 Finanční analýza

Úspěšná firma se při svém hospodaření bez rozboru finanční situace firmy již neobejde. Nejčastější rozborová metoda – finanční ukazatele – zpracovaná v rámci finanční analýzy se využívá při vyhodnocování úspěšnosti firemní strategie v návaznosti na ekonomické prostředí. Existuje celá řada způsobů, jak definovat pojem „finanční analýza“. V zásadě nejvýstižnější definicí je však ta, která říká, že finanční analýza představuje systematický rozbor získaných dat, která jsou obsažena především v účetních výkazech. Finanční analýzy v sobě zahrnují hodnocení firemní minulosti, současnosti a předpovídání budoucích finančních podmínek. (Růčková, 2021)

K základním metodám, které se při finanční analýze využívají, patří zejména: (Knápková et al., 2017)

- analýza stavových (absolutních) ukazatelů,
- analýza tokových ukazatelů,
- analýza rozdílových ukazatelů,
- analýza poměrových ukazatelů,
- analýza soustav ukazatelů,
- souhrnné ukazatele hospodaření.

Výsledkem finanční analýzy by mělo být celkové zhodnocení finanční situace podniku, odhalení jeho silných a slabých míst, identifikace významných činitelů ovlivňujících daný stav hospodaření a návrh doporučení pro zlepšení do budoucna. Závěrem finanční analýzy je potřeba uvést doporučení pro přijetí opatření ke zlepšení finančního zdraví podniku

v kontextu očekávaného vývoje vnějších podmínek a strategických záměrů podniku. (Knápková et al., 2017)

1.3 Okolí podniku

Podnik bývá vnímán jako koalice vzájemně se doplňujících zainteresovaných stran. Za tyto strany jsou považováni zákazníci, zaměstnanci, věřitelé, management, dodavatelé, stát a místní či regionální samospráva. Všechny tyto subjekty sledují vlastní cíle, avšak sdílí společný zájem na prosperitě podniku. (Bugri a Pribišová, 2017)

Finanční řízení a rozhodování není realizováno odděleně, ale je formováno okolními podmínkami různého charakteru od politických až po technologické. (Nývltová a Marinič, 2010)

Domácnostmi a firmami jsou činěna rozhodnutí, která ovlivňují nabídku, poptávku i cenu produktů. Firmy jsou zároveň nuceny čelit konkurenci ze strany ostatních podniků nabízejících podobné produkty. Díky konkurenčnímu tlaku bývá dosahováno efektivní alokace zdrojů, neboť jsou firmy motivovány k minimalizaci nákladů a zvyšování hodnoty pro zákazníky. (Mankiw, 2023)

V rámci tržní ekonomiky bývá rozdělení ekonomických zdrojů ovlivňováno soukromými rozhodnutími. Ceny na trzích fungují jako signál, podle něhož jsou vzácné ekonomické zdroje směřovány k optimálnímu využití. Rozlišují se následující typy trhů: (Fabozzi, 2015)

1. trh produktů – vyrobené zboží a služby,
2. trh výrobních faktorů – práce a kapitál.

1.3.1 Finanční trh

Finanční trh je považován za nedílnou součást finančního systému, jenž je definován jako komplexní mechanismus zajišťující plnění vzájemně souvisejících funkcí v rámci ekonomiky. Tímto trhem jsou do peněžního okruhu začleňovány dočasně volné peněžní prostředky, které by jinak zůstaly nevyužity. (Rejnuš, 2024)

Za základní funkci ekonomiky každého státu je považována alokace vzácných materiálových zdrojů, jejichž prostřednictvím může být efektivně zajišťována výroba zboží a poskytování služeb podle společenské poptávky. Tato funkce však může být naplněna pouze za předpokladu existence funkčního finančního systému. (Rejnuš, 2024)

Finančnímu trhu je připisována role snižování transakčních nákladů spojených s vyhledáváním a získáváním informací. Mezi jeho dvě klíčové ekonomické funkce patří podpora efektivní alokace finančních prostředků a zajištění dodatečné likvidity. Cena kapitálu je určována na základě nabídky a poptávky po finančních aktivech. (Fabozzi, 2015)

Za účelem zvýšení produkční kapacity bývá podniky investováno do fyzického kapitálu (stroje, budovy) a lidského kapitálu (vzdělání, dovednosti). Tyto investice musejí být financovány ze zdrojů, které mohou pocházet z interních úspor či externích úvěrů. (Mankiw, 2023)

Finanční kapitál je na finančním trhu směňován za méně likvidní nástroje, které přinášejí očekávaný budoucí výnos. (Rejnuš, 2024)

Subjekty s přebytkem či nedostatkem finančních zdrojů jsou v ekonomickém systému spojovány prostřednictvím finančního trhu. Přesun těchto prostředků od přebytkových jednotek k jednotkám deficitním, s cílem jejich efektivního a produktivního využití, se uskutečňuje prostřednictvím systému finančních trhů. (Nývtová a Marinič, 2010)

Finanční trh je tvořen několika segmenty, zejména trhem peněžním a kapitálovým. Dále se k němu řadí i poněkud specifické trhy, jako jsou trhy s cizími měnami a trhy drahých kovů. Peněžní a kapitálový trh může být dále členěn podle splatnosti na trhy krátkodobých a dlouhodobých úvěrů a cenných papírů. (Rejnuš, 2024)

Kapitálový trh je vymezen jako prostor pro obchod s dlouhodobými finančními nástroji. Na tomto trhu jsou poskytovány dlouhodobé úvěry a obchodovány cenné papíry s dlouhodobou splatností. (Rejnuš, 2024)

2 ŘÍZENÍ PODNIKU

V prostředí globální konkurence a rostoucí nejistoty je podnikové řízení orientováno na udržení konkurenceschopnosti prostřednictvím zvyšování hodnoty vytvářených produktů pro zákazníky a maximalizace tržní hodnoty podniku. (Martinovičová et al., 2019)

2.1 Podstata managementu

Termín management bývá vnímán jako synonymum českého výrazu řízení, avšak jeho význam je užší. Řízení se uplatňuje v technických, biologických i společenských systémech, zatímco management se vztahuje výhradně v organizacích a představuje specifickou formu řízení. Jedná se o řízení jednotlivců a skupin v účelově vytvořeném ekonomicko-sociálním prostředí. (Blažek, 2014)

Ve vztahu k podnikovému řízení je management definován jako sofistikovaný proces zaměřený na stanovení a dosažení podnikových cílů prostřednictvím manažerských funkcí. Klíčovou roli v tomto procesu hraje rozhodování, které se prolíná všemi jeho fázemi. (Vochozka a Mulač, 2012)

V současné době jsou manažerské funkce vymezeny jako: (Blažek, 2014)

- plánování,
- organizování,
- personalistika,
- vedení,
- kontrolování.

Vedení spočívá ve schopnosti přesvědčit ostatní, aby se s nadšením podíleli na plnění cílů. Manažerské činnosti, jako plánování, organizování a rozhodování, zůstávají neúčinné, dokud vedoucím pracovníkem není u podřízených podpořena motivace k dosažení stanovených cílů. (Vochozka a Mulač, 2012)

Kontrola (controlling) slouží jako nástroj zpětné vazby, který umožňuje porovnávat dosažené výsledky s původními plány. (Vochozka a Mulač, 2012)

Řízení podniků se neustále vyvíjí, což podporuje samostatné manažerské myšlení a jednání v souladu s rostoucími požadavky na rychlost, pohotovost a flexibilitu. V úspěšných podnicích je kladen důraz na vytváření podmínek umožňujících pružnou a rychlou reakci na vznikající podnikatelské příležitosti a současně na neustálý rozvoj strategických inovačních záměrů a projektů. (Martinovičová et al., 2019)

2.2 Manažerské rozhodování

Rozhodování představuje proces, při němž je hledáno optimální řešení problému s ohledem na stanovený cíl. Přitom musí existovat alespoň dvě varianty, jak problém vyřešit a tyto varianty jsou hodnoceny na základě jednoho, či více hodnotících faktorů (kritérií). (Zapletal, 2023)

V manažerské praxi se rozhodování uplatňuje při plánování, při tvorbě a změnách organizační struktury, při výběru pracovníků a obsazování pracovních míst, při tvorbě a úpravách motivačního systému, při řízení zaměstnanců i při nastavování a modifikaci kontrolních mechanismů. (Martinovičová et al., 2019)

Manažerské rozhodování probíhá v rámci vymezené působnosti manažera, přičemž rozhodnutí jsou činěna v zájmu nadřízeného, resp. zaměstnavatele. Jejich realizace je uskutečňována prostřednictvím podřízených osob. Ačkoli je rozhodovací proces ovlivňován svými morálními principy manažera a regulován právními i vnitřními předpisy organizace, obvykle zůstává značný prostor pro individuální rozhodování. (Blažek, 2014)

2.2.1 Manažerský proces

Rozhodovací proces představuje dynamický mechanismus, jehož prostřednictvím manažeri reagují na vzniklé problémy. Jeho průběh je ovlivňován celou řadou faktorů, mezi něž patří organizační prostředí, manažerovy dovednosti a motivace, kvalita podřízených. (Vochozka a Mulač, 2012)

Podstatou rozhodovacího procesu je volba alespoň mezi dvěma variantami řešení. Tento proces je chápán jako řešení rozhodovacích problémů, tedy situací, v nichž existuje více variant rozhodnutí. Pak situace, v nichž existuje či bylo nalezeno pouze jediné řešení, nelze považovat za rozhodovací problémy a jejich řešení není součástí rozhodovacího procesu. (Fotr a Švecová, 2022)

Vychází-li se z předpokladu, že základním atributem rozhodování je: (Fotr a Švecová, 2022)

- proces posuzování jednotlivých variant,
- výběr optimální varianty určené k realizaci.

Rozhodovací procesy se vyznačují několika základními prvky, mezi něž patří: (Fotr a Švecová, 2022)

- stanovení cíle rozhodování,
- definování rozhodovacích kritérií,
- určení subjektu a objektu rozhodování,
- formulace variant rozhodování a jejich důsledků,
- posouzení stavů světa.

2.2.2 Plánování

Plánování zahrnuje stanovení cílů a postupů k jejich dosažení. V rámci tohoto procesu jsou prováděny studie, analýzy a návrhy, přičemž je rozhodováno o nejvhodnějších variantách budoucího výkonu činností. Zároveň jsou zvažovány a plánovány potřebné informační, lidské, materiální a finanční zdroje. (Martinovičová et al., 2019)

Cíl představuje konečný stav, k němuž jsou směřovány veškeré plánované aktivity. V rámci podnikové struktury jsou cíle uplatňovány na všech úrovních a jejich hierarchie je organizována podle významu a rozsahu. (Vochozka a Mulač, 2012)

Dle Vochozky a Mulače je lze rozdělit do tří kategorií:

- strategické organizační cíle mají obecnější charakter a jsou otevřené,
- operativní cíle jsou více konkrétní a mohou být jak otevřené, tak uzavřené,
- operační cíle jsou specifické, uzavřené a vymezují kritéria výkonu, termíny plnění i požadované chování zaměstnanců.

Plán podniku slouží jako nástroj realizace podnikové strategie a musí být zpracován jako integrovaný celek. Dílčí plány musí být vzájemně věcně, časově a finančně provázané. (Martinovičová et al., 2019)

2.2.3 Organizování

Organizování navazuje na plánování a zajišťuje dosažení cílů vymezených plánovacím procesem. (Martinovičová et al., 2019) K jejich naplnění jsou ve firmách využívány

specializované činnosti vyplývající z dělby práce, přičemž jejich koordinace je nezbytná. Organizování je chápáno jako proces alokace lidských i ostatních zdrojů a jejich usměrňování k dosažení vytyčených cílů. (Vochozka a Mulač, 2012)

Základními parametry organizační struktury, které určují její architekturu, zahrnují: (Blažek, 2014)

- dělbu práce, která specifikuje přiřazení jednotlivých činností k pracovním místům,
- rozpětí řízení, jež souvisí s hierarchickým uspořádáním organizační struktury a určuje počet pracovníků přímo podřízených jednomu vedoucímu,
- dělbu pravomocí, která vymezuje způsob distribuce řídicí pravomoci.

2.3 Podnik a riziko

Přístupy k definování rizika se liší v závislosti na způsobu jeho chápání. Riziko je obvykle vnímáno jako hrozba, jež může negativně ovlivnit schopnost podniku dosahovat stanovených cílů a úspěšně naplňovat strategii. Zároveň však může představovat i příležitost, pokud je správně řízeno. (Vochozka a Mulač, 2012)

V průběhu historického vývoje bylo riziko primárně vnímáno jako ohrožení či nebezpečí, což je patrné i v současném vnímání (např. riziko onemocnění, havárie výrobního zařízení aj.). V tomto kontextu je riziko chápáno jako: (Fotr a Švecová, 2022)

- pravděpodobnost vzniku ztráty,
- možnost výskytu událostí, které mohou zabránit dosažení cílů jednotlivce či organizace,
- pravděpodobnost negativních odchylek od stanovených úrovní cílů jednotlivce či organizace.

Identifikace rizika tvoří klíčovou fázi risk managementu, jejímž cílem je stanovit způsoby jejich zvládnutí. Kvantifikace rizik je prováděna různými přístupy, přičemž se zjišťuje pravděpodobnost jejich výskytu, velikost možných škod nebo kombinace těchto faktorů. Řízení rizik se zaměřuje jak na jejich příčiny, tak na jejich důsledky. (Vochozka a Mulač, 2012)

Hodnocení rizika je prováděno na základě pravděpodobnosti jeho výskytu a rozsahu dopadu na podnik, a to jak v krátkodobém, tak i dlouhodobém časovém horizontu. Riziko by nemělo být vnímáno výhradně jako ekonomický jev, ale spíše jako prvek, který charakterizuje podnikatelskou činnost. (Vochozka a Mulač, 2012)

Podnikatelské riziko (riziko podnikatelských aktivit, projektu či podniku jako celku) je určováno jako možnost odchylky dosažených výsledků podnikatelské činnosti od výsledků předpokládaných. Tyto odchylky mohou být: (Fotr a Švecová, 2022)

- žádoucí (např. vedoucí k vyššímu zisku), nebo nežádoucí (vedoucí ke ztrátě),
- různý rozsah, od nevýznamných, kdy výsledky odpovídají očekávaným hodnotám, až po zásadní (výrazný podnikatelský úspěch či naopak finanční obtíže vedoucí až k úpadku).

2.3.1 Klasifikace rizik

Rizika mohou být klasifikována podle různých hledisek. Mezi základní způsoby jejich třídění patří: (Fotr a Švecová, 2022)

- podnikatelská a čistá:
 - podnikatelské riziko je spojováno s pozitivními a negativními dopady,
 - čisté riziko má pouze negativní charakter, neboť představuje nebezpečí vzniku nepříznivých situací či odchylek od žádoucího stavu;
- systematická a nesystematická,
 - systematické riziko je způsobeno makroekonomickými faktory a zasahuje všechny subjekty v různé intenzitě. Mezi jeho hlavní zdroje patří změny v peněžní a rozpočtové politice, změny v daňové legislativě nebo vývoj na trhu. Vzhledem k těmto změnám je označováno jako tržní riziko,
 - Nesystematické (jedinečné, specifické) riziko se vztahuje k jednotlivým podnikům a jejich činností. Může být způsobeno například odchodem klíčových pracovníků, selháním významného subdodavatele nebo vstupem nového konkurenta na trh;

- vnitřní a vnější:
 - vnitřní rizika souvisejí s interními faktory podniku, jako jsou technologická či personální,
 - vnější rizika jsou spojena s podnikatelským okolím a faktory, které nelze přímo ovlivnit;
- ovlivnitelná a neovlivnitelná:
 - ovlivnitelná rizika lze regulovat prostřednictvím vhodných opatření,
 - neovlivnitelná rizika (např. nepříznivé změny měnových kurzů, přírodní katastrofy) nelze eliminovat jejich vznik, avšak lze minimalizovat jejich negativní důsledky, například využitím pojištění či jiných strategií rizikového managementu.

Klasifikace rizik podle jejich věcné náplně je rozsáhlá a významná. Z tohoto hlediska se obvykle rozlišují technicko-technologická, výrobní, ekonomická, tržní, finanční, kreditní, legislativní, politická, environmentální rizika. (Fotr a Švecová, 2022)

2.3.2 Řízení rizika

Rozhodování ve finančním managementu je ovlivňováno především rizikem a časovým faktorem, který ovlivňuje hodnotu peněz. Vnímání rizika se liší v závislosti na osobnosti investora a jeho podnikatelském přístupu. (Nývtová a Marinič, 2010)

S ohledem na primární cíl maximalizace výnosu je rizikovost investic definována jako nejistota ohledně naplnění očekávané výnosnosti daného instrumentu. (Rejnuš, 2024)

Odhad rizikovosti investic je prováděn buď subjektivně jednotlivcem, nebo objektivně pomocí metod opírajících se o dlouhodobé sledování a statistické analýzy. (Rejnuš, 2024)

2.4 Finanční řízení podniku

Podnik je v moderních teoriích vnímán jako hodnotový řetězec, v němž dochází ke zhodnocení kapitálu prostřednictvím jeho opakované transformace. Výsledná hodnota, převyšující vstupní kapitál, je tvořena přidanou hodnotou jako kompenzací za podstoupené riziko a náklady spojené s investováním. (Nývtová a Marinič, 2010)

Za hlavní cíl podniku je považována maximalizace jeho hodnoty, což je doprovázeno růstem ekonomické, peněžní a tržní přidané hodnoty, rentability vlastního kapitálu, zisku na akcii a přidané hodnoty na jednoho zaměstnance. (Martinovičová et al., 2019)

Ve finančním řízení je kladen důraz na volbu vhodných externích (a následně i interních) zdrojů financování a na jejich efektivní využití v souladu s finančními cíli podniku a stanovenými omezeními. (Nývltová a Marinič, 2010)

K základním cílům finančního řízení podniku patří především dosažení finanční stability, která je hodnocena pomocí dvou základních kritérií: (Růčková, 2021)

- Schopnost generovat zisk, navyšovat majetek a zhodnocovat vložený kapitál – toto kritérium je obecně považováno za nejvýznamnější, neboť vystihuje podstatu podnikání.
- Zajištění platební schopnosti podniku – i když je tento aspekt vnímán jako sekundární, jeho nenaplnění zpravidla vede k nemožnosti dalšího fungování podniku a k ukončení jeho činnosti.

Dlouhodobý finanční plán je koncipován jako hlavní nástroj finančního řízení. V návaznosti na investiční, výrobní a prodejní plány je jím stanovena výše, struktura a využití kapitálu a zároveň je posuzováno, zda jsou naplňovány podnikové cíle a očekávané přínosy pro vlastníky. (Nývltová a Marinič, 2010)

3 SOFT COMPUTING

„Chováním jednotlivých prvků v dané struktuře se dá vysvětlit chování celku.“ (Dostál, 2015)

3.1 Úvod

Soft computing je charakterizován jako soubor výpočetních technik, jimiž jsou aproximována řešení složitých problémů. Mezi jeho klíčové komponenty jsou řazeny fuzzy logika, neuronové sítě a evoluční výpočty. (Díaz-Cortés et al., 2017)

V rozhodovacích procesech je uplatňována operační analýza, při níž jsou k řešení komplexních ekonomických, organizačních, technických nebo vojenských problémů využívány matematické modely a specifické kvantitativní metody. Cílem těchto postupů je nalezení optimálního řešení podle stanovených kritérií. (Sojka et al., 2005)

Pokročilé metody manažerského rozhodování (např. fuzzy logika, umělé neuronové sítě, genetické algoritmy) jsou využívány k získávání kvantitativních podkladů pro rozhodování výkonných orgánů a návrh optimálních systémových řešení. Jejich aplikací bývá dosaženo vyšší kvality rozhodovacích procesů, zejména u úloh s více kritérii a obtížnou algoritmizací. (Sojka et al., 2005)

3.1.1 Podstata

Soft computing je považován za oblast počítačové vědy, v jejímž rámci jsou vyvíjeny inteligentní systémy. Tyto systémy jsou navrhovány tak, aby napodobovaly inteligentní procesy, které čerpají inspiraci z výpočetních modelů i přírodních nebo biologických mechanismů. (Díaz-Cortés et al., 2017)

Soft computing je definován jako soubor metod a technik určených k řešení složitých úloh, které se vyznačují neurčitostí, nepřesností nebo neúplnou informací. (Dymowa, 2011)

Tyto metody byly úspěšně aplikovány při řešení mnoha inženýrských aplikací. Oproti klasickým metodám napodobením kognitivních prvků, včetně získávání znalostí na základě zkušeností. (Díaz-Cortés et al., 2017)

Soft computing je inspirován biologickými a přírodními systémy: (Díaz-Cortés et al., 2017)

- lidské uvažování je napodobováno prostřednictvím fuzzy logiky,

- propojení mozkových buněk neuronů je simulováno neuronovými sítěmi,
- evoluční algoritmy jsou založeny na principech Darwinovy evoluce.

Vedle těchto přístupů jsou využívány i metody jako strojové učení a pravděpodobnostní uvažování, Bayesovské sítě a expertní systémy. (Díaz-Cortés et al., 2017)

Při řešení složitých problémů nejsou lidmi běžně využívány přesné numerické hodnoty, ale spíše vágní jazykové pojmy typu „daleko“, „blízko“, „rychle“ či „pomalu“. Uvažování tedy probíhá v pojmech přirozeného jazyka, nikoli v přesných číslech. Technické zpracování těchto úloh je předmětem zkoumání umělé inteligence. (Jura, 2003)

3.1.2 Historie

Podle Dymowé (2011) byla pravděpodobně první aplikací soft computingových metod ve finanční oblasti implementace teorie fuzzy množin v procesu rozpočtování. V současnosti se matematické nástroje teorie fuzzy množin a fuzzy logiky úspěšně využívají především v oblasti analýzy rizik.

Konec 20. století byl charakteristický rozsáhlými změnami, které zásadním způsobem ovlivnily sociální, ekonomické i podnikové prostředí. Tyto změny probíhají mimořádně rychle, a spolu s nimi narůstá i složitost a proměnlivost problémů, které je nutné v rámci rozhodovacích procesů řešit. Tradiční přístupy založené výhradně na determinismu a pravděpodobnosti již v mnoha případech nedostačují. V reakci na tuto skutečnost se v posledních čtyřech desetiletích vyvinula skupina nových metod označovaných jako soft computing, jež umožňují efektivně pracovat s neurčitostí, která není vyjádřitelná klasickou pravděpodobností. Mezi těmito metodami se v ekonomických a finančních aplikacích nejčastěji používají právě nástroje fuzzy teorie množin. (Dymowa, 2011)

3.1.3 Pojmy

Systémovým přístupem označujeme takový způsob myšlení, řešení úloh a jednání, při němž jsou jevy chápány v jejich vnitřních souvislostech, tedy komplexně. Tento přístup klade důraz na důsledné respektování vazeb mezi prvky vstupujícími do úlohy a rovněž na vazby k jeho významnému okolí. (Dostál, 2015a)

Komplexní myšlení, které úzce souvisí se systémovým myšlením, představuje úrovnově vyvážený způsob myšlení založený na komplexním posouzení všech aspektů

souvisejících s analyzovaným objektem, procesem či s řešeným problémem. (Janíček a Marek, 2013)

Systém je (účelově definovaná) množina prvků (objektů) a vazeb mezi nimi, která je na základě filozofických kategorií „část“ a „celek“ chápána jako struktura prvků natolik propojených, že (navenek) vystupuje jako jeden celek. (Sojka et al., 2005)

Za prvek systému je považována ta část celku, která je na zvolené rozlišovací úrovni nedělitelná a jejíž vnitřní struktura není rozlišovaná, ať už záměrně, nebo z důvodu nemožnosti ji identifikovat. (Dostál, 2015a)

Entitou je chápán jakýkoli prvek, který může být samostatně uvažován, a to bez ohledu na jeho charakter – může jít o objekt, subjekt, proces, stav, činnost, službu či jiný hmotný nebo nehmotný výsledek lidské činnosti. (Janíček a Marek, 2013)

Každý systém je možné charakterizovat prostřednictvím jeho strukturou a chováním. Strukturou bývá označována množinu prvků a vazeb, které jej tvoří. Chování systému je vymezováno jako jeho reakce na vnější či vnitřní podněty a je podmíněno jeho vlastnostmi. (Sojka et al., 2005)

K řešení problémů týkajících se systémových objektů byla vytvořena systémová metoda označovaná jako systémová analýza a syntéza. Tato metoda (v kombinaci s dalšími postupy využívanými v technických i netechnických oborech – např. logika, experiment, modelování, matematická statistika, logistika, mezní stavy, teorie chaosu) tvoří základ systémových disciplín s nadoborovým přesahem. (Janíček a Marek, 2013)

Systémová metodologie je definována jako průnik systémového přístupu, myšlení, systémových disciplín a algoritmů. (Janíček a Marek, 2013)

Klasická množina je definována jako soubor prvků libovolného druhu. Může být konečná, spočetná i nespočetná. Její určení se provádí buď výčtem všech prvků, které do množiny patří, nebo prostřednictvím vlastnosti, která určuje příslušnost prvku do množiny. (Jura, 2003)

V rámci optimalizace je usilováno o nalezení extrému dané funkce $f(x)$ na dané množině M . Tato množina, označovaná jako množina přípustných řešení, bývá specifikována pomocí omezení, zpravidla ve formě rovnic nebo nerovnic. (Dostál, 2015b)

Časová řada je vyjádřena jako posloupnost hodnot závislých na čase t . Hodnotu v čase $t = 1$ je označena x_1 , v čase $t = 2$ x_2 atd. Hodnota x_N odpovídá časovému okamžiku v čase

$t = N$, kde N značí celkový počet hodnot časové řady. Celá řada může být matematicky reprezentována jako vektor hodnot $x = (x_1, x_2, \dots, x_N)$. (Dostál, 2015b)

Modelování je využíváno jako efektivní nástroj pro řešení problémů prostřednictvím modelového objektu. V závislosti na jeho charakteru bývá modelování členěno na mentální, datové, znalostní, materiální (experimentální), abstraktní (výpočtové) a hybridní. (Janíček a Marek, 2013)

Predikce je proces, který je iniciován před výskytem události, upravován v jejím průběhu a uzavírán po jejím skončení prostřednictvím vyhodnocení. (Dostál, 2015b)

3.2 Metody

Pokročilé metody manažerského rozhodování (fuzzy logika, umělé neuronové sítě, genetické algoritmy a metody chaosu) jsou využívány k získání kvantitativních podkladů jak pro rozhodování výkonných orgánů o řízených operacích, tak pro navrhování optimálních systémů. Jejich výsledky přispívají ke zkvalitnění rozhodovacího procesu, a to zejména u multikriteriálních a obtížně algoritmizovaných úloh. (Sojka et al., 2005)

Soft computingové metody nacházejí uplatnění v širokém spektru analýz a modelování v různých oblastech – od optimalizace a simulace technologických procesů přes rozhodování směřující k optimálním výsledkům až po odhady cen výrobků, objemu výroby, oceňování nemovitostí, posuzování bonity klienta za účelem poskytnutí úvěru. (Dostál, 2015a)

3.2.1 Fuzzy logika

Pojem „fuzzy“ pochází z angličtiny a znamená „mlhavý, nejasný, neostrý, neurčitý“. Fuzzy logika tedy vyjadřuje přístup k logickému uvažování, který zohledňuje neurčitost a nepřesnost jazykových výpovědí. Logika jako vědní disciplína se zabývá zákony správného myšlení a pravidly nezbytnými pro vyvozování správných závěrů. V tradiční logice může být každému tvrzení přiřazena hodnota „pravda“ nebo „nepravda“, což však odpovídá idealizovaným podmínkám, nikoli složitosti reálného světa. (Jura, 2003)

Pomocí fuzzy logiky je umožněno operovat s neurčitými jazykovými výrazy, jako jsou např. velmi nízké riziko, nízké riziko, střední riziko, vysoké riziko, velmi vysoké riziko nebo kvality typu velmi špatný, špatný, průměrný, dobrý, velmi dobrý apod. (Dostál, 2015a)

V klasické Aristotelově logice, formulované již před více než dvěma tisíci lety, byl každému výroku přiřazen jeden ze dvou možných stavů: pravda a nepravda. Mezi těmito

hodnotami neexistovala žádná střední varianta; prvek buď do množiny patří nebo nepatří. (Dostál, 2015a)

Základy moderní vícehodnotové logiky byly položeny v roce 1920. Prvním systémem, který připustil existenci třetí možnosti kromě pravdy a nepravdy, byla tříhodnotová logika prezentovaná polským logikem Janem Łukasiewiczem. Tato třetí hodnota byla označena „možnost“ a poprvé byla představena na přednášce pro polskou filozofickou společnost ve Lvově. (Bělohlávek et al., 2017)

Ve třicátých letech 20 století byla Łukasiewiczem jeho tříhodnotová logika rozšířena o nekonečně mnoho pravdivostních hodnot, čímž byly položeny základy moderní vícehodnotové logiky. Na jeho práci následně navázalo mnoho dalších logiků. (Dostál, 2015a)

Za zakladatele teorie fuzzy množin je považován Lofti Askar Zadeh, který v roce 1965 publikoval článek Fuzzy sets. Právě v tomto textu byl poprvé použit termín „fuzzy množina“. Zadeh vycházel z předpokladu existence množin s neostře definovanou hranicí. Na rozdíl od klasické množiny, která je jednoznačně popsána pomocí funkce, fuzzy množina představuje její zobecnění, které je vyjádřeno funkcí definovanou na intervalu $[0-1]$. (Dostál, 2015a)

Ve fuzzy množinách je určován stupeň příslušnosti prvků k dané množině, tedy míra, s jakou prvek do množiny patří nebo nepatří. Fuzzy logikou je tak vyjadřována míra jistoty nebo nejistoty této příslušnosti. (Sojka et al., 2005) Podobným způsobem je rozhodováno i v běžném lidském uvažování při řešení úloh, které nejsou zcela algoritmizovatelné, ať už v oblasti duševní, či fyzické činnosti. Pomocí fuzzy logiky mohou být z dostupných pravidel odvozena řešení konkrétních situací v oblasti řízení firem. (Dostál, 2015a)

Pro účely matematického zpracování veličin vyjádřených byla zavedena tzv. jazyková proměnná, která je definovaná na určitém intervalu tzv. bazových proměnných. Tento interval je označován jako univerzum, nad nímž je jazyková proměnná vyjádřena množinou jazykových hodnot. Kvantifikace těchto hodnot je možná pouze prostřednictvím fuzzy množiny. (Janíček, 2014)

Proces zpracování ve fuzzy systému se skládá ze tří hlavních kroků: fuzzifikace, fuzzy inference a defuzzifikace. Reálné proměnné jsou transformovány na jazykové proměnné, ty jsou následně přiřazeny k fuzzy množinám prostřednictvím funkcí příslušnosti. (Sojka et al., 2005)

Cílem fuzzifikace je tedy převod ostré hodnoty proměnné na fuzzy množinu. Tento proces lze realizovat tak, že vstupní ostré číslo je interpretováno jako za fuzzy číslo se specifickým typem funkce příslušnosti, tzv. singletonem, přičemž toto číslo následně náleží do fuzzy množiny. (Jura, 2003)

Na rozdíl od klasických množin, ve fuzzy množinách neplatí pouze dvě možnosti – že prvek do množiny buď patří, nebo nepatří. Fuzzy množiny umožňují určovat stupeň příslušnosti prvku, tedy míru, do jaké daný prvek do množiny náleží. Tento vztah je popsán pomocí funkce příslušnosti, která mapuje univerzum do intervalu hodnot mezi 0 a 1. (Jura, 2003)

Naopak cílem defuzzifikace je převod výsledné fuzzy množiny zpět na ostrou hodnotu dané veličiny, tedy na konkrétní číselný výstup. (Jura, 2003)

Metoda pracující s fuzzy množinami patří mezi moderní přístupy využívané v oblasti řízení firem, zejména tam, kde je potřeba konkrétní číselný výstup. (Sojka et al., 2005)

Dostál (2015a) uvádí řadu oblastí, v nichž lze efektivně využít metody soft computingu. Podle něj může být fuzzy logika aplikována například v těchto situacích:

- rozhodování o koupi nemovitosti,
- rozhodování o přijetí/odmítnutí klienta,
- rozhodování banky o poskytnutí hypotečního úvěru klientu,
- rozhodování, zda ve firmě provádět benchmarking,
- rozhodování o realizaci investic.

Další možnosti využití fuzzy logiky v podnikové ekonomice zahrnují zejména následující (Sojka et al., 2005):

- umožňuje řídit skladové zásoby při nejisté poptávce a optimalizovat objednávky,
- umožňuje personalizovaná doporučení produktů podle neurčitých zákaznických preferencí,
- používá se v expertních systémech pro podporu manažerského rozhodování v nejistých podmínkách,
- usnadňuje hodnocení kandidátů při náboru na základě subjektivních kritérií.

Dle Dymowe (2011) je teorie fuzzy množin často využívána v ekonomických a finančních aplikacích pro modelování neprobabilistické nejistoty. V ekonomii a financích se fuzzy množiny používají například pro hodnocení investic, kde je třeba brát v úvahu faktory, které nelze přesně predikovat a často jsou vyjádřeny verbálně. Dále se využívají pro modelování expertních znalostí v rozhodovacích systémech pro obchodování s akcemi. (Dymowa, 2011)

Nástroje fuzzy logiky dle Sojky (2005) a ostatních jsou následující:


- Excel,
- FuzzyTech,
- MATLAB – Fuzzy Logic Toolbox.

3.2.2 Umělé neuronové sítě

Neuronové sítě, které představují jednu z variant výpočetních modelů používaných v umělé inteligenci, jsou stále častěji diskutovány v souvislosti s dynamickým rozvojem moderních informačních technologií. (Vochozka et al., 2017)

Umělá neuronová síť jakožto analytický nástroj simuluje myšlenkové procesy člověka prostřednictvím specifických algoritmů. Svým principem fungování lze neuronová síť chápat jako model biologické nervové soustavy, přičemž její struktura připomíná uspořádání neuronů – základních stavebních jednotek této soustavy. (Vochozka et al., 2017)

Biologický neuron si lze zjednodušeně představit podle obrázku 1. Skládá se z více vstupů (dendritů), těla (somatu) a jednoho výstupu (axonu). Vstupy jsou v buňce zpracovány a výstupní signál je dále přenášen axonem až k zakončení (synapsím). Tyto synapse pak ovlivňují dendrity dalších neuronů a zajišťují tak přenos informace v rámci celé nervové sítě. (Sojka et al., 2005)



Obrázek 1 Schéma biologického neuronu (Sojka et al., 2005)

Umělý neuron, označovaný také jako formální neuron, je charakterizován konečným počtem vstupů, které do něj vstupují. Tyto vstupy lze připodobnit dendritům biologických buněk – přenášejí informace do „těla“ neuronu, kde dochází k jejich zpracování. Umělý neuron má stejně jako nervová buňka vždy pouze jeden výstup, jehož úkolem je předávat dále zpracovanou informaci. (Vochozka et al., 2017)

Jelikož neuronová síť představuje počítačový či matematický model biologické nervové soustavy, vykazuje s ní určitou podobnost i po funkční stránce. Slouží jako analytický nástroj, který na základě zadaných vstupních hodnot provádí jejich vyhodnocení a generuje výstupy. Tyto výstupy mohou být částečně definovány předem, přičemž jejich konkrétní podoba závisí na způsobu strukturování sítě a zvoleném algoritmu učení. (Vochozka et al., 2017)

Umělé neuronové sítě (ANN) jsou označovány jak tzv. „černá skříňka“, jelikož jejich vnitřní struktura není zcela transparentní. Při modelování systémů tímto způsobem se obvykle definují pouze základní předpoklady, které umožňují popsat chování systému prostřednictvím funkce realizující transformaci mezi vstupy a výstupy. Neuronové sítě jsou vhodným nástrojem v případech, kdy je modelovaný proces ovlivňován náhodnými vlivy a deterministické závislosti jsou natolik složité a provázané, že je nelze analyticky oddělit či jednoznačně identifikovat. Jsou proto využívány zejména při modelování komplexních, často nevratných strategických rozhodnutí, jako je například investiční rozhodování. (Sojka et al., 2005)

Funkce umělé neuronové sítě jako „černé skříňky“ probíhá zpravidla ve dvou fázích. V první fázi plní síť roli „zvědavého žáka“, kdy se na základě trénovacích dat učí nastavit své parametry tak, aby odpovídaly požadované topologii sítě a optimalizovaly výstup. Ve druhé fázi přechází síť do role „odborníka“, kdy na základě získaných znalostí generuje výstupy pro nové vstupy. Při návrhu neuronové sítě je nezbytné stanovit strukturu sítě, tj. rozvržení jednotlivých vrstev (vstupní, skrytá, výstupní), počet vstupních a výstupních neuronů, způsob propojení mezi jednotlivými vrstvami (formulace přenosových funkcí), způsob učení (s učitelem, bez učitele, v epochách) a mechanismus akumulace a využívání získaných znalostí. (Sojka et al., 2005)

Díky tomu, že umělé neuronové sítě představují počítačový model biologických neuronových struktur, je možné jejich využití i v lékařském výzkumu, zejména při studiu fungování lidského mozku či nervové soustavy živých organismů obecně. (Vochozka et al., 2017)

ANN lze rovněž porovnávat s tradičními statistickými nástroji používanými k prognózování. Jak uvádí Dymowa (2011): Neuronové sítě umožňují aproximovat jak lineární, tak nelineární funkce a dosahují vynikajících výsledků v aplikacích zaměřených na klasifikaci, predikci budoucích hodnot, modelování a řízení procesů“. (Dymowa, 2011)

Dle Vochozky (2017) lze neuronové sítě využít v široké škále oblastí, mezi než patří průmyslová výroba a obchod, bankovníctví a finančníctví, lékařství, doprava, energetika a vodní hospodářství, meteorologie, zemědělství, bezpečnostní a obranné systémy, ekonomie, ekologie, a další vědní disciplíny.

Dymowa (2011) dále uvádí konkrétní příklady aplikace umělých neuronových sítí v ekonomickém a finančním prostředí:

- předpověď bankrotu a audit,
- včasná predikce ekonomické krize: ekonomické krize v 90. letech podnítily potřebu systémů včasného varování. ANN se zkoumají jako nástroj pro trénování těchto systémů,
- řešení problémů rozvrhování výroby: je popsána neuronová síť pro problém rozvrhování dílenské výroby, jejíž struktura a propojení neuronů se adaptivně mění podle aktuálních omezení,
- předpověď a obchodování na akciových trzích: analýza denní a týdenní předvídatelnosti výnosů akcií na mnoha trzích pomocí lineárních i nelineárních modelů ANN.

Neuronové sítě mají schopnost extrahovat pravidla a trendy i z velmi složitých datových struktur. Jednou z jejich klíčových vlastností je schopnost zobecnění – tedy predikce hodnot, které nebyly obsaženy ve trénovacích datech, což při správné aplikaci umožňuje dosahovat vysoké přesnosti výsledků. Díky tomu jsou neuronové sítě využívány v celé řadě odvětví. (Uldrich a Jurczyk, 2014)

Uldrich a Jurczyk (2014) uvádějí následující příklady, kde se neuronové sítě aplikují nejčastěji:

- odhad dynamické stability u energetických systémů,
- rozpoznání poruch strojů a výpočetní techniky,
- lékařství – detekce a odhad velikosti tumoru, chemická diagnostika,

- dopravní signalizace,
- rozpoznání kvality výrobku bez nutnosti laboratorních experimentů,
- samoobslužné mechanismy (subsystémy řízení budov),
- optické rozpoznávání textů, písma a podpisů,
- systémy pro převod mluvené řeči do písemné podoby,
- odhad kvality ropných produktů.

Dostál (2015a) uvádí několik konkrétních oblastí, v nichž lze neuronové sítě efektivně využít, například:

- predikce hodnot časové řady – výpočet vývoje kurzu měny dolaru k české koruně,
- řešení klasifikačních problémů,
- vygenerování klíče.

Neuronové sítě si postupně získaly pevné místo také ve finančním rozhodování. Výsledky výzkumu zaměřené na schopnost těchto sítí předvídat finanční výkonnost však zůstávají nejednoznačné. Srovnání jednotlivých studií je komplikováno rozdílnými metodologickými přístupy a použitými evaluačními kritérii. Přesto jsou publikovány výsledky, které umožňují částečné hodnocení efektivity neuronových sítí, například při výběru akcií nebo sestavování investičních portfolií. (Dymowa, 2011)

3.2.3 Teorie chaosu

Teorie chaosu, původně formulovaná v oblasti technických věd, se zabývá chováním nelineárních systémů, které vykazují určitou vnitřní strukturu a skrytý řád, ale přesto se jeví jako systémy řízené náhodnými jevy. Procesy v ekonomice mají nelineární charakter. Je-li v systému přítomná nelineární dynamika, může deterministický systém generovat náhodně vyhlížející výsledky, které ale mohou zahrnovat trvalejší trendy a cykly. Také ekonomika se může nacházet ve stavu s různou mírou řádu, chaosu a nahodilosti. Např. řádné fungování ekonomiky je narušeno přírodními katastrofami, politickými změnami atd. (Sojka et al., 2005)

S chaosem jsou spojovány tyto pojmy: neuspořádanost, nepředvídatelnost, nejednoznačnost, nepochopitelnost, nesrozumitelnost, nepřehlednost, nejasnost, nepořádek. V současnosti rozlišujeme: (Janíček a Marek, 2013)

- chaos subjektivý – ten se vyskytuje u člověka a může být přímý nebo nepřímý,
- chaos objektivý – je to chaos vznikající na objektech.

Deterministický chaos se vyskytuje u nelineárních dynamických soustav, které jsou za určitých podmínek vysoce citlivé na odchylky ve vstupních datech do algoritmů řešení procesů. Procesy jsou deterministicky popsány, ale vykazují nepředvídatelné (chaotické) chování. (Janíček a Marek, 2013)

V souvislosti s chaotickými systémy bývá zmiňován pojem atraktor. Atraktor představuje stavovou veličinu, která určuje rovnovážný stav systému (např. ekonomického). Tento rovnovážný stav však nemusí být statický – může se vyvíjet v čase, přičemž systém zůstává v jeho blízkosti. (Sojka et al., 2005)


Atraktory popisují způsob, jakým se systémy chovají, a představují vzorce nebo body, ke kterým systém tíhne. Mohou popisovat koncové stavy systému. Chování systému může být ovlivněno zpětnovazebními mechanismy (pozitivními a negativními). Atraktory souvisejí s uspořádanými hranicemi – tedy s limity, v rámci kterých systémy fungují, a s vizemi reality, které mohou působit jako atraktory ovlivňující jednotlivce. (Pryor a Bright, 2011)

Atraktor může být: (Sojka et al., 2005)

- bodový, kdy rovnováha je představována bodem, např. kyvadlo,
- cyklický, kdy rovnováha je představována limitním cyklem, např. dodáváme kyvadlu stálou energii,
- chaotický, kdy hovoříme o tzv. dynamické rovnováze, např. dodáváme kyvadlu energii nepravidelně.

Pryor a Bright (2011) k tomuto členění dodávají ještě torusový atraktor, kdy se systém opakuje, ale nikdy se neopakuje přesně stejně, sleduje předvídatelnou, ale komplexní cestu.

Chaotický atraktor si lze představit následovně:



Obrázek 2 Znázornění chaotického atraktoru (Sojka et al., 2005)

Oblast stability je definována pásmem mezi vnější a vnitřní elipsou, v němž je zakreslována trajektorie systému, jež nikdy nepřebírá stejnou podobu. Protože je usilováno o stabilitu systému, je tato trajektorie přitahována (angl. slovo attract znamená přitahovat) k prostřední elipse. (Dostál, 2015a)

Jedním z klíčových konceptů spojených s teorií chaosu je „Motýlí efekt“, který zdůrazňuje citlivost na počáteční podmínky – malé změny v počátečním stavu mohou vést k dramaticky odlišným, nepoměrným výsledkům v pozdějším čase. (Pryor a Bright, 2011)

Dostál (2015a) dále uvádí využití teorie chaosu zejména při vyhodnocování časových řad, přičemž predikce ekonomického vývoje je omezena současnými znalostmi, což činí dlouhodobé předpovědi nejisté. (Dostál, 2015a)

3.2.4 Genetické algoritmy

Genetické algoritmy jsou v současnosti nejrozšířenější a nejpropracovanější metodou aplikovanou v oblasti podnikatelství a veřejné správy. Jsou využívány zejména v případech, kdy by nalezení vyžadovalo extrémní výpočetní čas. Díky tomu umožňují efektivní řešení složitých problémů velmi elegantně. Inspirací pro jejich vznik se staly genetické procesy pozorované v přírodě, které byly popsány již v 19. stol. J.G. Mendelem a dále rozvíjeny Charlesem Darwinem. Na základě svých pokusů Mendel formuloval tři pravidla, která později vešla ve známost jako Mendelovy zákony. (Dostál, 2015a)

Průkopníkem v oblasti genetických algoritmů byl John Holland, jenž se zabýval studiem elementárních procesů v populacích, které jsou z evolučního hlediska nepostradatelné. Na základě těchto výzkumů byl genetický algoritmus navržen jako abstrakce odpovídajících biologických procesů. (Hynek, 2008)

Genetické algoritmy jsou založeny na myšlence darwinovského principu evoluce. Hledání optimálního (nebo alespoň dostatečně vyhovujícího) řešení je realizováno formou soutěže v rámci populace postupně se vyvíjejících řešení. Aby bylo možné určit, která individua mají větší pravděpodobnost podílet se na vývoji hledaného řešení, musí být jejich způsobilost kvantifikována. V této souvislosti se mluví o ohodnocení, míře kvality, vhodnosti, síle či reprodukční schopnosti individua. (Hynek, 2008)

Genetické algoritmy jsou běžně využívány k řešení rozmanitých optimalizačních úloh. Jednoduché extrémální úlohy bývají navíc často využívány k názornému předvedení jejich snadné aplikovatelnosti a funkčnosti těchto algoritmů. (Hynek, 2008)

3.2.5 Shrnutí dalších soft computingových metod

Datamining neboli „dolování dat“ je oborem, který zastřešuje širokou škálu technik, používaných v řadě odvětví. (Dostál, 2015a)

Algoritmus dolování dat je dobře definovaný postup, který přijímá data jako vstup a produkuje výstup ve formě modelů nebo vzorů. Cílem algoritmů dolování dat je často najít modely nebo vzory, které dobře zobecňují na nová, neviděná data a vyhnout se přeučení dané datové sady. Volba skórovací funkce by měla toto zohlednit. (Hand et al., 2001)

Cílem podniku je dosažení vyššího zisku, snížení nákladů a minimalizace rizika ztrát. K naplnění tohoto cíle napomáhá datamining, prostřednictvím něhož jsou získávána a vyhodnocována data, na jejichž základě mohou být identifikováni noví zákazníci, odhaleni riziková zákazníci a vytipováni zákazníci, které by bylo možné ztratit. (Dostál, 2015a)

Model chování zákazníka může být chápán jako odladěný program, v němž je využita fuzzy logika, neuronové sítě nebo evoluční algoritmy. Pro výpočet takových modelů je nezbytné získání kvalitních a relevantních zdrojových dat. (Dostál, 2015a)

Dostálem (2015a) je uvedeno následující využití dataminingu:

- aplikace fuzzy logiky na příkladu přímého marketingu – zda zákazníka navštívit osobně, zaslat mu dopis nebo zákazníka neoslovovat,

- aplikace neuronové sítě na příkladu vyhodnocení míry rizikovosti klienta, která může být hodnocena škálou 0 až 100 %.

Evoluční algoritmy jsou využívány při řešení rozmanitých problémů, s nimiž se lze setkat v oblasti řízení podniků a veřejné správy. Ve srovnání s tradičními vyhledávacími algoritmy je jejich přínos spatřován zejména ve schopnosti efektivněji nalézat globální extrém, tedy řešení blízké se optimálnímu. (Dostál, 2015a)

Hlavním důvodem, proč jsou tyto typy algoritmů navrhovány a testovány, je jejich předpokládaná aplikace např. v oblasti rozvrhování výroby, sestavování výukových rozvrhů, optimalizace ekonomických problémů či optimalizace technických systémů s časově proměnlivou účelovou funkcí. Optimalizací prostřednictvím evolučních algoritmů může být dosaženo vyšší kvality řešení daných úloh a zkvalitnění rozhodování, což se může odrazit v minimalizaci rizik, ztrát a nákladů. (Dostál, 2015a)

4 SHRNUÍ TEORETICKÉ ČÁSTI

Podniková ekonomika je vědní disciplína, která se zaměřuje na podnik jako instituci. Studuje jeho cíle, funkce, organizační struktury a řízení. Podnik je instituce zřízená k podnikatelské činnosti, jejímž cílem je vyrábět a tržně realizovat produkty a služby pro zákazníky a zároveň uspokojovat potřeby těch, kteří jsou s podnikem spjati. Primárním účelem podniku je generování zisku. Efektivnost podniku je vyjádřena jeho schopností vyrábět produkty uspokojující tržní poptávku při optimálním využití výrobních faktorů.

Podnikatel je nositel podnikání, fyzická nebo právnická osoba, právně samostatný a vlastnický oddělený subjekt, vykonávající činnost vlastním jménem a na svou zodpovědnost.

Obchodní společnosti se dělí na osobní (veřejná obchodní společnost, komanditní společnost) a kapitálové (společnost s ručením omezeným, akciová společnost). Klasifikace podle velikosti dělí podniky na velké, střední, malé a mikropodniky. Kritéria zahrnují počet zaměstnanců, roční obrát, hodnotu majetku nebo zisku.

Hospodaření podniku je sledováno pomocí rozvahy, základního účetního výkazu poskytujícího přehled o struktuře majetku (aktiva) a zdrojích financování (pasiva), přičemž aktiva se musí rovnat pasivům.

Finanční analýza je systematický rozbor dat z účetních výkazů. Slouží k vyhodnocování úspěšnosti firemní strategie, hodnocení minulosti, současnosti a předpovídání budoucích finančních podmínek.

Okolí podniku formuje finanční řízení a rozhodování. Finanční trh je nedílnou součástí finančního systému a spojuje subjekty s přebytkem/nedostatkem finančních zdrojů.

Manažerské rozhodování je klíčová role v procesu řízení. Je to hledání optimálního řešení problému s ohledem na cíl, přičemž musí existovat alespoň dvě varianty řešení. Prvky rozhodovacího procesu zahrnují stanovení cíle, definování kritérií, určení subjektu/objektu, formulaci variant a posouzení stavů. Riziko je vnímáno jako hrozba, která může negativně ovlivnit cíle, ale i jako příležitost, pokud je řízeno. Identifikace rizika je klíčová fáze risk managementu.

Pokročilé metody manažerského rozhodování, jako fuzzy logika, umělé neuronové sítě a genetické algoritmy, umožňují získat kvantitativní podklady pro rozhodování a navrhování optimálních systémů. Tyto metody spadají pod soft computing, soubor výpočetních technik

zabývajících se aproximací řešení složitých problémů zahrnujících neurčitost a nepřesnost. Inspiraci čerpají z přírodních jevů nebo biologických systémů.

Soft computingové metody v oblasti podnikové ekonomiky mohou být využity k optimalizaci procesů, predikci trendů, rozhodování v podmínkách nejistoty a automatizaci analýzy dat.

Fuzzy logika umožňuje modelovat riziko a nejistotu ve finančním rozhodování, například stanovení finančních toků u investičního projektu.

Neuronové sítě se používají k predikci akciových trhů, měnových kurzů, cen komodit, predikci poptávky, automatizovanému hodnocení bonity klientů, detekci podvodů, simulaci rozhodovacích procesů a analýze výkonu zaměstnanců.

Teorie chaosu pomáhá identifikovat skryté vzory v pohybech cen, měn, komodit, určit rychlost odchylky trhu od rovnováhy, přizpůsobit investiční strategie. Pomáhá identifikovat situace náhlých změn (např. cash flow) a predikovat sezónní výkyvy a náhlé změny poptávky. Nelineární modely pomáhají optimalizovat produkční strategie a snižovat odpad.

Evoluční algoritmy optimalizují investiční strategie, podnikové strategie (cenová politika, řízení kapacit), a pomáhají identifikovat vzorce podvodného jednání. Genetické algoritmy optimalizují plánování směn a schvalovací kritéria úvěrů.

II PRAKTICKÁ ČÁST

5 ANALÝZA MOŽNOSTÍ VYUŽITÍ SOFT COMPUTINGOVÝCH METOD

Soft computingové metody jsou v oblasti podnikové ekonomiky využívány k optimalizaci procesů, predikci trendů, podpoře rozhodování v podmínkách nejistoty a automatizaci analýzy dat.

5.1 Využití fuzzy logiky v podnikové ekonomice

Podle Dostála (2015a) může být fuzzy logiky využita například při rozhodování advokátní kanceláře o přijetí klienta. Tento přístup je snadno adaptovatelný i na rozhodovací procesy v jiných typech podniků, například při výběru klienta nebo dodavatele.

Dostál (2015b) uvádí využití fuzzy logiky v ekonomickém výzkumu, zejména při predikci ekonomických časových řad a volatility kapitálových trhů. V podnicích je fuzzy logika využívána při řízení vztahů se zákazníky a řízení zdrojů, což umožňuje snížit náklady, zvýšit zisk a přispět tak k efektivnějšímu provozu firmy. Dále je uvedena možnost modelování časových řad a použití fuzzy logiky při nákupu a prodeji na finančních trzích.

Konkrétní využití fuzzy logiky je popsáno v bakalářské práci Schejbalové (2021), kde je řešeno rozhodování o koupi podnikového vozidla. Nejprve je ukázáno, jak by rozhodnutí vypadalo na základě jednotlivých kritérií: nejnížší ceny, nejmenšího počtu najetých kilometrů a typu převodovky. V rámci každého kritéria jsou vybrány tři odpovídající vozy, přičemž se pokaždé jedná o jinou trojici. Pro účely rozhodování pomocí fuzzy logiky je vytvořena tabulka obsahující intervaly pro cenu, počet najetých kilometrů a platnost technické kontroly. Hodnocení je provedeno pomocí tabulek a matic v programu Excel. Jednotlivým kritériím byly přiděleny body dle preferencí. Zmíněna je i možnost využití fuzzy logiky při výběru povinného ručení k autu.

Ve své bakalářské práci se Koňářík (2024) zabýval hodnocením finančního zdraví za pomoci fuzzy logiky. Vytvořený model fuzzy analýzy byl využit ke srovnání tří firem na základě vypočtených ukazatelů aktivity, rentability, likvidity a zadluženosti.

Čejkou (2008) byly v bakalářské práci navrženy finanční modely, které umožňující realizovat riziko a nejistotu přítomnou ve finančním rozhodování. Jako příklad bylo uvedeno rozhodování firmy o investičním projektu s tříletou životností, kde jsou budoucí finanční toky určovány pomocí fuzzy logiky. Dále bylo popsáno posouzení finančního zdraví

podniku za pomoci simulačního prostředí Fuzzy toolbox pro Matlab na základě ukazatelů rentability, zadluženosti a likvidity.

Doskočilem (2009) byla v jeho disertační práci zpracována metodika zjišťování bonity klienta v pojišťovnictví za pomoci využití fuzzy logiky.

Praktický příklad využití fuzzy logiky ve firmě popsal Jura (2003), jedná se o použití fuzzy regulátoru při řízení teploty v sušící peci.

Další využití fuzzy logiky bylo popsáno Dostálem (2017):

- Problematika potenciálu států z podnikatelského hlediska, kdy je rozhodování podnikatele o vstupu na zahraniční trh modelováno fuzzy logikou.
- Aproximace časových řad, přičemž byla zdůrazněna výhoda u ekonomických řad s vysokou mírou chaotičnosti.

Hašková (2021) představila aplikace fuzzy logiky v následujících případech:

- rozhodování manažera při výběru jednoho ze dvou výrobních zařízení,
- odhad rizika zahraničních investic na základě hodnot ratingových indexů,
- hodnocení ekonomické efektivnosti projektů v podmínkách nejistoty, zaměřené na rentabilitu investic,
- hodnocení ekonomické efektivnosti investičních projektů s přihlédnutím k zásahům manažerů.

Podle Dymowe (2011) je fuzzy logika využívána při vícenásobném rozhodování, například pro porovnání fuzzy čísel nebo intervalů. K dalším oblastem aplikace patří:

- výběr materiálu nástrojové oceli,
- hodnocení investičních projektů,
- stock screening (výběr akcií) a hodnocení akcií, přičemž fuzzy logika tvoří základ expertních systémů pro podporu obchodování na akciových trzích,
- hodnocení a optimalizace rozpočtování,
- analýza ziskovosti,
- posouzení fuzzy čisté hodnoty a rizika,

- řešení problému distribuce pomocí rozšíření simplexové metody, které využívá pravidla fuzzy aritmetiky a metodu porovnání fuzzy hodnot.

5.2 Využití neuronových sítí v podnikové ekonomice

Dle Dymowe (2011) lze neuronové sítě využít v následujících oblastech:

- Předpověď bankrotu a audit – ANN jsou vhodné pro predikci bankrotu, neboť se jedná o složitou oblast, která dosud postrádá jednotnou teorii, avšak disponuje rozsáhlými datovými soubory. ANN se rovněž využívají pro audit a hodnocení rizik.
- Včasná predikce ekonomické krize – neuronové sítě se zkoumají jako nástroj pro trénování systémů včasného varování.
- Řešení problémů rozvrhování výroby – např. při řešení problému průtokové dílny s cílem minimalizovat průměrný čas průchodu výrobním systémem.
- Předpověď a obchodování na akciových trzích – neuronové sítě se využívají k predikci výnosů akcií pomocí lineárních i nelineárních modelů. Výzkumy však ukazují, že nelineární modely neposkytují výrazně lepší výsledky než modely lineární a že po zohlednění transakčních nákladů zůstávají akciové trhy obecně nepředvídatelné.
- Finanční rozhodování – výzkumy zaměřené na schopnost neuronových sítí předpovídat finanční výkonnost přinášejí smíšené výsledky. Srovnání jednotlivých studií je navíc obtížné z důvodu rozdílných metodických přístupů a hodnotících kritérií.

Dymowa (2011) uvádí konkrétní příklad využití umělých neuronových sítí při charakterizaci vztahu mezi vstupy a výrobou elektřiny jako výstupem. Zároveň navrhuje alternativní metodu input – output analýzy založenou na vrstveném modelu neuronové sítě, která je vhodná pro modelování dynamických ekonomických systémů.

Další využití neuronových sítí, zejména v oblasti podnikové ekonomiky, uvádí Vochozka (2017). Podle něj mohou neuronové sítě sloužit pro:

- predikci časových řad,
- operativní řízení v čase,

- tvorbu modelů spotřeby,
- stanovení burzovních indexů,
- klasifikaci výsledků akciové společnosti,
- zpracování marketingových studií,
- řízení pracovních operací i celého výrobního procesu,
- investiční rozhodování,
- odhady cen výrobků a množstevní odhady,
- oceňování bonity klienta,
- rating podniků – bonita, riziko bankrotu,
- předpověď obchodního úspěchu podniku – na základě tržeb z produkce vlastního zboží a služeb; investiční zisky,
- předpověď bankrotu obchodních bank, finanční situaci podniků v jednotlivých hospodářských odvětvích,
- predikce hrubého domácího produktu a modelu spotřeby.

Dostál (2017) uvádí využití neuronových sítí v oblasti podnikové ekonomiky například pro:

- detekci pravděpodobnosti odchodu zákazníka,
- predikci časových řad se sezónní a trendovou složkou.

V habilitační práci Šuleř (2023) uvádí, že neuronové sítě patří mezi nejpopulárnější nelineární prognostické metody v ekonomii. Díky schopnosti pracovat s větším množstvím proměnných jsou často využívány k predikci vývoje jednotlivých sektorů, cen akcií či komodit. Uplatnění nacházejí také v oblasti bankrotních modelů, kde samostatně – nebo častěji ve spojení s dalšími metodami – překonávají tradiční statistické přístupy.

Šťastný, Pokorný a Motyčka (2007) se ve svém výzkumu věnovali aplikaci metod umělé inteligence v ekonomické oblasti. Identifikovali několik oblastí využití:

- predikce vývoje ekonomických ukazatelů pomocí modelu pro odhad trendu vícevrstvé perceptronové neuronové sítě,
- implementace podnikových rozhodovacích procesů a pravidel,

- identifikace zákaznických preferencí.

Součástí výzkumu byl také projekt klasifikace podnikové finanční situace, který řeší úlohu přiřazení podniku do jedné z předem definovaných kategorií. Vstupními proměnnými byly finanční ukazatele likvidity, zadluženosti, aktivity a rentability. Výstupní klasifikační kategorie lze stanovit finančním expertem s ohledem na specifika daného tržního segmentu a časového období tak, aby odpovídala běžně využívaným typům hodnocení. (Šťastný et al., 2007)

Další možnosti využití umělých neuronových sítí v ekonomické praxi uvádějí Uldrich a Jurczyk (2014), a to:

- predikci reakce spotřebitelů na nové zboží,
- detekce úvěrového rizika,
- identifikaci potenciálních pojistných podvodů.

Neuronové sítě (Umělá inteligence, 2025):

- pomáhají při predikci poptávky po zboží na základě sezónních trendů a historických dat;
- simulují složité rozhodovací procesy na základě historických dat;
- pomáhají při analýze výkonu zaměstnanců a predikce fluktuace pracovníků;
- používají se k detekci podvodného chování v účetnictví nebo při transakcích.

Dymowa (2011) se mimo jiné zabývá využitím kombinace fuzzy logiky a umělých neuronových sítí, tuto možnost nazývá fuzzy neuronová síť. Tyto hybridní modely propojují výhody obou přístupů – schopnost zpracovávat neurčitou a jazykové proměnné (fuzzy logika) a schopnost učení z dat (neuronové sítě). Uplatnění fuzzy neuronových sítí se nachází především v následujících oblastech:

- inteligentní systém na podporu obchodování s akcemi,
- rozhodování a obchodování na spekulativních akciových trzích, a to zejména díky schopnosti predikce potenciálních zlomových bodů, které mohou vést k významně vyšším výnosům.

5.3 Využití teorie chaosu

Mandelbrot a Hudson (2008) uvádějí, že finanční trhy nevykazují stabilní a předvídatelné chování, jak se často předpokládá v klasické ekonomii, ale naopak se chovají chaoticky a fraktálně. Teorie chaosu zde nachází využití při analýze časových řad cen akcií a komodit, modelování volatilních tržních pohybů a včasné detekci bublin a kolapsů. Fraktální struktury umožňují zachytit komplexní a opakující se vzory, které by jinak zůstaly skryté, a tím přispívají k lepší správě investičních portfolií a řízení rizik.

Praktické využití těchto principů demonstruje diplomová práce Sadila (2016), která analyzuje data z finančních trhů pomocí R/S analýzy. Elliottových vln a Fibonacciho nástrojů. Výstupy těchto analýz slouží jako podklad pro obchodní rozhodnutí.

Tuto teorii ilustruje diplomová práce Hnilické (2019), která se věnuje kvalitativní analýze modelů hospodářského cyklu typu akcelérátor-multiplikátor. Zaměřuje se na Hicksův model celkového výstupu ekonomiky a jeho různé varianty, přičemž analyzuje stabilitu a chaotické chování v těchto modelech.

Možnosti využití teorie chaosu (Umělá inteligence, 2025):

- pomáhá identifikovat skryté vzory v pohybech cen, měn nebo komodit;
- pomáhá určit, jak rychle se trh odchyluje od rovnováhy, což je užitečné při modelování volatility;
- umožňuje přizpůsobit investiční strategie podle chaotických tržních trendů;
- pomocí chaotických modelů lze nastavit lepší strategie pro zvládání nečekaných krizí;
- pomáhá identifikovat situace, kdy může dojít k náhlým změnám, například v cash flow nebo ve finanční stabilitě firmy;
- chaotické modely pomáhají předpovídat sezónní výkyvy a náhlé změny, protože poptávka po produktech často nevykazuje lineární růst;
- nelineární modely umožňují optimalizovat produkční strategie a snižovat odpad, vzhledem k tomu, že výrobní linky podléhají složité dynamice;
- pomáhá pochopit, jak se nové technologie šíří v podniku a jaké faktory ovlivňují rychlost adaptace na změny.

5.4 Možnosti využití dalších soft computingových metod

Maděra (2024) se zabývá aplikací genetických algoritmů při trénování neuronových sítí pro analýzu vysokofrekvenčních finančních dat. Uvádí, že evoluční algoritmy umožňují efektivní optimalizaci parametrů neuronových sítí, což vede k přesnějším predikcím finančních trhů. Praktické využití spočívá v automatizovaném obchodování, kde optimalizované modely mohou reagovat na rychlé změny na trhu a tím zvyšovat ziskovost obchodních strategií.

Nguyen (2011) se zaměřuje na využití evolučních algoritmů pro řešení kontinuálních dynamických optimalizačních problémů. Uvádí, že tyto algoritmy jsou schopny adaptivně reagovat na změny v prostředí, což je klíčové pro podniky operující v dynamických trzích. Praktické využití zahrnuje optimalizaci výrobních procesů, řízení zásob nebo plánování logistiky, kde je potřeba neustále přizpůsobovat strategie aktuálním podmínkám.

Palmer (2019) se zabývá aplikací evolučních algoritmů v oblasti oceňování derivátů. Uvádí, že tyto algoritmy umožňují efektivní hledání optimálních parametrů v komplexních finančních modelech, což vede k přesnějšímu oceňování finančních nástrojů. Praktické využití spočívá v oblasti finančního inženýrství, kde přesné oceňování derivátů je klíčové pro řízení rizik a tvorbu investičních strategií.

Korf (2020) se ve své bakalářské práci zabývá využitím optimalizačních metod, konkrétně rozhodovacích stromů, v ekonomii. Uvádí, že tyto metody umožňují efektivní modelování rozhodovacích procesů a mohou být optimalizovány pomocí evolučních algoritmů. Praktické využití spočívá v oblasti ekonomického modelování a predikce, kde optimalizované rozhodovací stromy mohou zlepšit přesnost a interpretovatelnost modelů.

Evoluční algoritmy (Umělá inteligence, 2025):

- optimalizují investiční strategie na základě simulace tržního chování;
- optimalizují podnikové strategie (např. tvorbu cenové politiky, řízení výrobních kapacit;
- pomáhají identifikovat vzorce podvodného jednání a optimalizovat kontrolní mechanismy.

Genetické algoritmy (Umělá inteligence, 2025):

- optimalizují plánování směn a rozvržení pracovních týmů;

- optimalizují schvalovací kritéria úvěrů na základě tržních podmínek.

Soft computing umožňuje firmám zlepšit konkurenceschopnost, automatizovat složité procesy a snížit rizika spojená s podnikáním v nejistém prostředí.

6 MODEL FUZZY LOGIKY PRO HODNOCENÍ FINANČNÍHO ZDRAVÍ PODNIKŮ

V této části práce je analyzován příklad z předmětu Podnikové finance I, který se zaměřuje na hodnocení finanční výkonnosti podniku pomocí ukazatelů rentability, zadluženosti a obratovosti. (Příklad byl převzat ze sbírky příkladů k tomuto předmětu – Knápková, 2024).

Zadání příkladu je následující: Dvě navzájem srovnatelné firmy dosáhly ve vybraných ukazatelích následujících výsledků:

Tabulka 2 Zadání příkladu (vlastní zpracování)

<i>Ukazatel</i>	<i>Firma A</i>	<i>Firma B</i>
<i>Čistý zisk</i>	60	90
<i>Dlouhodobý majetek</i>	180	200
<i>Oběžný majetek</i>	320	400
<i>Krátkodobé závazky</i>	100	300
<i>Vlastní kapitál</i>	300	200
<i>Dlouhodobé závazky</i>	100	100
<i>Tržby</i>	800	1500

Nejprve je znázorněno řešení příkladu bez využití metod soft computingu. Analýza začíná výpočtem vybraných finančních ukazatelů, k jejichž určení je nejprve nezbytné stanovit příslušné položky aktiv a pasiv.

Do aktiv se řadí dlouhodobý majetek a oběžná aktiva. Na straně pasiv jsou zahrnuty vlastní kapitál, krátkodobé závazky a dlouhodobé závazky. Položky, jako je čistý zisk a tržby, nejsou v této fázi výpočtu do rozvahy zahrnovány. Základní bilanční princip – aktiva se rovnají pasivům – musí být dodržen. Vypočtené hodnoty aktiv, pasiv a cizího kapitálu jsou přehledně uvedeny v následující tabulce:

Tabulka 3 Vypočtené hodnoty (vlastní zpracování)

	<i>Firma A</i>	<i>Firma B</i>
<i>Aktiva</i>	500	600
<i>Pasiva</i>	500	600
<i>Cizí kapitál</i>	200	200

Pro potřeby výpočtu budou využity následující poměrové ukazatele: rentabilita vlastního kapitálu (ROE), běžná likvidita (BL), celková zadluženost (CZ) a obrat aktiv (OA). Tyto ukazatele se počítají podle standardizovaných vzorců, které byly převzaty od Knápkové et al. (2017):

$$\text{rentabilita vlastního kapitálu} = \frac{\text{čistý zisk}}{\text{vlastní kapitál}}$$

$$\text{běžná likvidita} = \frac{\text{oběžná aktiva}}{\text{krátkodobé závazky}}$$

$$\text{celková zadluženost} = \frac{\text{cizí kapitál}}{\text{aktiva}}$$

$$\text{obrat aktiv} = \frac{\text{tržby}}{\text{aktiva}}$$

Hodnoty jednotlivých ukazatelů byly vypočteny a následně přehledně shrnuty v tabulce 4 (všechny údaje jsou zaokrouhleny na dvě desetinná místa):

Tabulka 4 Vypočtené hodnoty ukazatelů (vlastní zpracování)

	<i>Firma A</i>	<i>Firma B</i>
<i>ROE</i>	0,20	0,45
<i>BL</i>	3,20	1,33
<i>CZ</i>	0,40	0,67
<i>OA</i>	1,60	2,50

Uvedené hodnoty samy o sobě neposkytují dostatečný základ pro posouzení finanční situace jednotlivých podniků. Pro jejich interpretaci je vhodné porovnat je s doporučenými hodnotami například podle Knápkové et al. (2017), které jsou následující:

- Rentabilita vlastního kapitálu (ROE) – měla by být kladná, neboť vyjadřuje výnosnost kapitálu vloženého vlastníky
- Běžná likvidita (BL) – doporučené rozmezí je 1,5 až 2,5
- Celková zadluženost (CZ) – optimální hodnota se pohybuje mezi 30 – 60 %
- Obrat aktiv (OA) – doporučená minimální hodnota činí 1

Na základě analýzy poměrových ukazatelů lze konstatovat následující: Oba podniky dosahují kladné rentability, a tudíž lze usuzovat na jejich schopnost generovat zisk. U podniku A byla zjištěna nižší hodnota rentability vlastního kapitálu, což indikuje prostor pro zlepšení. Likvidita tohoto podniku je velmi dobrá, zatímco u podniku B dosahuje hodnot blízkých spodní hranici doporučeného intervalu. Zadluženost u firmy A odpovídá obecným doporučením, zatímco firma B tuto hranici téměř překračuje, což může být považováno za varovný signál. Využití aktiv je u obou podniků efektivní.

Toto hodnocení je však do značné míry subjektivní, neboť závisí na odborných znalostech a zkušenostech hodnotitele, a proto může být vhodné využít formalizovaný přístup založený na fuzzy logice. Za tímto účelem bude v prostředí programu Excel vytvořen model fuzzy logiky, který umožní přiřazení slovního hodnocení finančního zdraví na základě

bodového ohodnocení jednotlivých ukazatelů. Tato případová studie byla zpracována na základě příkladu využití fuzzy logiky v prostředí programu Excel Dostálem (2015a).

Sestavení transformační matice představuje jeden z podstatných kroků při hodnocení finančního zdraví podniků. Jednotlivým ukazatelům je v ní přisuzována bodová hodnota podle jejich významu a rozsahu možných výsledků. Celkem počet 100 bodů je rozdělen rovnoměrně mezi čtyři ukazatele (každý po 25 bodech), přičemž konkrétní bodové rozložení zohledňuje variabilitu jejich hodnot. Vzhledem k tomu, že zadluženost reflektuje míru rizika spojeného s platební schopností, je v transformační matici ohodnocena výrazněji. Stejný postup je uplatněn i u rentability, která signalizuje schopnost podniku dosahovat zisku. Příslušné hodnoty a klasifikace jsou uvedeny v následujících tabulkách.

Tabulka 5 Rozsah hodnot a bodové hodnocení rentability vlastního kapitálu

(vlastní zpracování)

<i>ROE</i>	<i>Hodnoty od</i>	<i>Hodnoty do</i>	<i>Bodové hodnocení</i>	<i>Slovní hodnocení</i>
1	<0	0	2	záporná
2	0,1	0,3	4	nízká
3	0,4	0,6	8	vyhovující
4	0,7	1	11	vysoká

Tabulka 6 Rozsah hodnot a bodové hodnocení běžné likvidity (vlastní zpracování)

<i>BL</i>	<i>Hodnoty od</i>	<i>Hodnoty do</i>	<i>Bodové hodnocení</i>	<i>Slovní hodnocení</i>
1	0	1	2	velmi nízká
2	1,1	1,5	4	nízká
3	1,6	2,5	5	ideální

<i>BL</i>	<i>Hodnoty od</i>	<i>Hodnoty do</i>	<i>Bodové hodnocení</i>	<i>Slovní hodnocení</i>
4	2,5	3	6	vysoká
5	3,1	5	8	velmi vysoká

Tabulka 7 Rozsah hodnot a bodové hodnocení celkové zadluženosti (vlastní zpracování)

<i>CZ</i>	<i>Hodnoty od</i>	<i>Hodnoty do</i>	<i>Bodové hodnocení</i>	<i>Slovní hodnocení</i>
1	0	0,3	7	nízká
2	0,31	0,6	13	optimální
3	0,61	1	5	vysoká

Tabulka 8 Rozsah hodnot a bodové hodnocení obratovosti aktiv (vlastní zpracování)

<i>OA</i>	<i>Hodnoty od</i>	<i>Hodnoty do</i>	<i>Bodové hodnocení</i>	<i>Slovní hodnocení</i>
1	0	1	4	neefektivní
2	1,1	2	5	nízká
3	2,1	3	7	efektivní
4	3,1	5	9	vysoká

Bodové hodnocení uvedené v jednotlivých tabulkách bylo následně shrnuto do již zmíněné transformační matice, viz tabulka 9.

Tabulka 9 Transformační matice (vlastní zpracování)

	<i>ROE</i>	<i>BL</i>	<i>CZ</i>	<i>OA</i>	
1	2	2	7	4	
2	4	4	13	5	
3	8	5	5	7	
4	11	6		9	
5		8			
MAX	11	8	13	9	41
min	2	2	5	4	13

Do transformační matice byly doplněny také dva řádky, v nichž jsou uvedeny maximální a minimální hodnoty jednotlivých sloupců a jejich součet. K jejich získání byly využity funkce Excelu MAX, MIN a SUMA.

V dalším kroku byla vytvořena pomocná tabulka, ve které byly jednotlivým vypočteným hodnotám ukazatelů přiřazeny body z transformační matice pomocí funkce SVYHLEDAT.

Tabulka 10 Body přiřazené vypočteným hodnotám (vlastní zpracování)

	<i>Firma A</i>	<i>Firma B</i>
<i>ROE</i>	4	8
<i>BL</i>	8	4
<i>CZ</i>	13	5
<i>OA</i>	5	7

Na základě této tabulky byla sestavena stavová matice, ve které byly pomocí funkce KDYŽ porovnány hodnoty s transformační maticí. V případě shody bodové hodnoty byla přiřazena hodnota 1, v opačném případě 0. Tento krok byl klíčový pro správný výpočet stavové rovnice. Pro každou firmu byla sestavena samostatná stavová matice.

Tabulka 11 Stavová matice firmy A (vlastní zpracování)

	<i>ROE</i>	<i>BL</i>	<i>CZ</i>	<i>OA</i>
1	0	0	0	0
2	1	0	1	1
3	0	0	0	0
4	0	0	0	0
5	0	1	0	0

Tabulka 12 Stavová matice firmy B (vlastní zpracování)

	<i>ROE</i>	<i>BL</i>	<i>CZ</i>	<i>OA</i>
1	0	0	0	0
2	0	1	0	0
3	1	0	1	1
4	0	0	0	0
5	0	0	0	0

V dalším kroku byl vypočten skalární součin transformační a stavové matice, jehož výsledkem je bodové hodnocení finančního zdraví podniku. V případě nesprávného

sestavení stavové matice, například při porovnání pouze s maximálními hodnotami, by výsledek odpovídal součtu těchto maxim.

Pro konečné hodnocení finančního zdraví podniku bylo stanoveno bodové rozmezí, ke kterému byla přiřazena odpovídající jazyková proměnná ve formě stručného slovního hodnocení. Toto hodnocení bylo shrnuto do retransformační matice.

Tabulka 13 Retransformační matice (vlastní zpracování)

<i>Body od</i>	<i>Body do</i>	<i>Finanční zdraví</i>
0	19	<i>velmi nezdravá</i>
20	39	<i>nezdravá</i>
40	59	<i>optimální</i>
60	79	<i>zdravá</i>
80	100	<i>vynikající zdraví</i>

Skalární součin pro výpočet konkrétních hodnot měl podobu znázorněnou na obrázku 3. Od získané hodnoty skalárního součinu byla odečtena suma minimálních hodnot bodového hodnocení (viz transformační matice), přičemž tento rozdíl byl následně dělen rozdílem sumy maximálních a minimálních hodnot. Celý výsledek byl poté vynásoben stem. (Buňky G10 až J14 odpovídají transformační matici, buňky M19 až P23 představují stavovou matici v prostředí programu Excel).

Písmo	Zarovnání	Číslo
=100*((SOUČIN.SKALÁRNÍ(G10:J14;M19:P23)-K16)/(K15-K16))		
I	J	K
5	7	velmi vysoká

Obrázek 3 Vzorec skalárního součinu (snímek obrazovky programu Excel, vlastní zpracování)

Výsledky skalárního součinu, jsou uvedeny v následující tabulce:

Tabulka 14 Výsledek skalárního součinu matic (vlastní zpracování)

	Výsledek skalárního součinu	Slovní ohodnocení
Hodnocení firmy A	60,71429	zdravá
Hodnocení firmy B	39,28571	nezdravá

Hodnocení získané prostřednictvím modelu fuzzy logiky vytvořeného v prostředí Excelu se odlišuje od předchozího návrhu, který vycházel pouze z konkrétních vypočtených hodnot. Toto fuzzy hodnocení je značně zjednodušené a jeho výsledek je ovlivněn způsobem bodového rozdělení vstupních hodnot, které je vždy určeno subjektivním úsudkem hodnotitele. Lze tedy konstatovat, že výstup modelu je do značné míry závislý na zkušenostech a odborných znalostech hodnotitele. Zadané hodnoty a způsob jejich jazykového vyjádření tak zásadně ovlivňují výslednou interpretaci.

7 NÁVRH MODELU NEURONOVÉ SÍTĚ PRO PREDIKCI SPOTŘEBY MATERIÁLU

Byl vytvořen návrh modelu umělé neuronové sítě pro predikci spotřeby materiálu ve výrobním podniku, na základě různých vstupních faktorů. Model byl sestaven pomocí umělé inteligence v programovacím jazyce R.

7.1 Úvod, popis problému a cíl

Výrobní podniky čelí výzvám přesného plánování spotřeby materiálu, které je klíčové pro optimalizaci nákladů a efektivní využití zdrojů. Cílem této případové studie je navrhnout a implementovat regresní model založený na neuronové síti, který bude predikovat spotřebu materiálu na základě vstupních faktorů. Tento model je realizován v programovacím jazyce R s využitím knihovny nnet. (Knihovna nnet je součástí základního balíčku R a slouží k trénování jednoduchých umělých neuronových sítí pro klasifikaci i regresi).

Spotřeba materiálu ve výrobním podniku je ovlivněna různými faktory, jako je počet vyrobených produktů, teplota v prostředí, počet odpracovaných hodin a typ použitého materiálu. Cílem je vytvořit model, který na základě těchto proměnných dokáže odhadnout spotřebu materiálu, a tím podpořit rozhodovací procesy ve firmě při plánování nákupu a distribuci zdrojů.

Předpokládáme, že každý výrobek je složen ze tří různých surovin, přičemž každá z nich se spotřebovává v odlišném množství. Díky přesnější predikci bude možné lépe plánovat nákup materiálu a zamezit zbytečnému přezásobením nebo nedostatku surovin, což spěje k optimalizaci provozu a snížení nákladů.

Cílem je vytvořit predikční model založený na umělé neuronové síti, který bude schopen na základě vstupních faktorů odhadnout očekávanou spotřebu materiálu. Tento model bude sloužit jako podpůrný nástroj pro plánování zásobování a řízení výroby.

7.2 Obecný návrh architektury modelu neuronové sítě

Z pohledu návrhu komplexního modelu pro predikci spotřeby materiálu by bylo možné využít pokročilejší architekturu neuronové sítě skládající se z:

- Skrytá LSTM vrstva: 32 neuronů; umožňuje zachytit potenciální časové závislosti v datech, např. vývoj spotřeby v čase (Tato vnitřní vrstva obsahuje 32 „paměťových“ kanálů, jejím cílem je zachytit časové závislosti v datech).

- Dense (plně propojená) vrstva: s 16 neurony a aktivační funkcí ReLU [Dense vrstva je základní stavební blok neuronových sítí. ReLU (Rectified Linear Unit) je nelineární aktivační funkce, umožňuje modelu zachytit nelineární vztahy mezi vstupy a výstupy].
- Výstupní vrstva: 1 neuronem a lineární aktivací: predikuje spojitou hodnotu spotřeby materiálu

Tato architektura by byla vhodná zejména pro sekvenční nebo časové datové sady. Vzhledem k tomu, že data použitá v této případové studii nemají časovou strukturu a cílem je ukázat praktickou aplikaci, byla pro samotnou realizaci zvolena jednodušší struktura modelu pomocí knihovny nnet.

Funkce ztráty – Mean Squared Error (MSE) – použita pro trénink modelu a vyhodnocení predikční přesnosti. MSE pomáhá během tréninku řídit učení neuronové sítě (minimalizuje chybu mezi výstupem modelu a skuteností. Po tréninku kvantitativně vyhodnotit, jak dobře model predikuje spotřebu materiálu.

Optimalizátor – Adam (Adaptive Moment Estimation) – standardní algoritmus vhodný pro trénink hlubokých neuronových sítí. V této případové studii je Adam použit jako optimalizátor neuronové sítě při minimalizaci ztrátové funkce (MSE). Je vhodný zejména pro regresní úlohy s více vstupními faktory, protože se dobře přizpůsobuje různorodé škále vstupních dat.

Parametry učení:

- Počet epoch: 100

Jedno epocha znamená, že síť prošla všemi trénovacími daty jednou. Síť bude trénována opakovaně přes celý trénovací dataset 100 x, což umožňuje modelu postupně snižovat chybu a lépe se naučit vztahy mezi vstupy a výstupy.

- Velikost batch: 16

Batch je malý výběr vzorků z trénovacích dat, který se použije při jednom kroku učení. Při tréninku se model učí na 16 příkladech najednou, což představuje kompromis mezi rychlostí a stabilitou učení.

- Regularizace: Dropout 0.2 a L2 penalizace na Dense vrstvě

Dropout náhodně „vypíná“ (ignoruje) 20 % neuronů během trénování, aby síť nebyla závislá na konkrétních kombinacích neuronů. Tím pomáhá zabránit přeučení tím, že model se učí robustnější reprezentaci bez spoléhání na konkrétní neurony.

L2 penalizace penalizuje velké váhy ve vrstvě přidáním jejich čtverce do ztrátové funkce. Udrží váhy malé => model je jednodušší a lépe generalizuje.

7.3 Obecný postup řešení

1. Generování syntetických (umělých) dat simulujících provoz výrobního podniku s různými typy materiálu a spotřebou tří odlišných surovin

Cílem je vytvořit realistický dataset simulující provoz výrobního podniku, kde se používají tři typy materiálu (např. A, B, C) a různé proměnné ovlivňující jejich spotřebu. Postup:

- Vygenerují se vstupní proměnné: počet vyrobených produktů, teplota prostředí, počet pracovních hodin a typ materiálu
- Spotřeba materiálu (cílová proměnná) je spočtena jako kombinace těchto vstupů s přidáním náhodného šumu

2. Rozdělení dat na trénovací a testovací množinu v poměru 80:20

Ověření, že model generalizuje i na neznámá data, a není přeučen na data, která už „viděl“. 80 % dat je použito pro trénink modelu. 20 % dat je vyčleněno jako testovací sada, na které se ověří, jak dobře model predikuje na neznámých vstupech. Bez oddělení dat by bylo riziko, že model pouze „memoruje“ tréninková data, ale nebude fungovat v reálném provozu.

3. Trénink modelu neuronové sítě pomocí knihovny TensorFlow/Keras (alternativně implementovatelné v R pomocí balíčku keras)

Cílem je naučit model odhadovat spotřebu materiálu na základě zadaných vstupních proměnných. Výsledkem je model, který optimalizuje váhy neuronů tak, aby co nejlépe odpovídal skutečné spotřebě.

4. Vyhodnocení modelu pomocí MSE

Porovnání predikovaných hodnot se skutečnými hodnotami spotřeby. MSE měří průměrnou čtvercovou chybu mezi těmito hodnotami. Slouží i pro srovnání více modelů.

Nižší MSE = lepší model.

5. Vizualizace výsledků: grafické porovnání predikovaných a skutečných hodnot spotřeby materiálu

Výstupy

1. Vytrénovaný model neuronové sítě s optimalizovanou strukturou a parametry
2. Grafy porovnání mezi skutečnou a predikovanou spotřebou pro všechny tři suroviny
3. Hodnocení výkonu pomocí hodnoty MSE pro testovací množinu

Navržený model využívá sílu LSTM neuronové sítě v kombinaci s hustou (Dense) vrstvou k predikci spotřeby tří různých surovin. Model dokáže zohlednit více vstupních faktorů a predikovat více výstupních proměnných najednou. Díky syntetickým datům bylo možné model otestovat v kontrolovaných podmínkách. Výsledky ukázaly, že predikce je přesná a dobře koreluje se skutečnými hodnotami, což potvrzuje praktickou využitelnost tohoto přístupu pro plánování zásobování ve výrobním prostředí.

7.4 Použitá metodika a popis konkrétního modelu v R – příklad tří surovin

Pro modelování byla použita neuronová síť s jednou skrytou vrstvou obsahující 15 neuronů. Model byl implementován pomocí knihovny nnet v R.

Konfigurace modelu:

- Funkce aktivace: lineární (regresní úloha)

Výstupní neuron nemá žádnou nelineární aktivační funkci, ale pouze předává vypočtenou hodnotu dále.

- Regularizace: decay = 0.1

Tento parametr v knihovně nnet v R odpovídá L2 regularizaci, která penalizuje příliš velké váhy modelu. Cílem je zabránit přeučení.

- Počet iterací: 1000

Iterace znamená jeden krok, při kterém model projde určitým množstvím dat a upraví své váhy na základě výpočtu chyby. Počet iterací trénování modelu nad daty, ve kterých se model snaží minimalizovat chybu mezi predikcí a skutečnou hodnotou.

- Hodnocení: Mean Squared Error (MSE)

Použitá ztrátová funkce, která měří průměrný čtverec rozdílu mezi predikovanou a skutečnou hodnotou.

Vstupní proměnné

1. Počet produktů – počet jednotek, které byly ve sledovaném období vyrobeny
2. Teplota – průměrná teplota v hale během výroby, která může ovlivnit efektivitu výrobního procesu
3. Počet pracovních hodin – celkový počet hodin odpracovaný ve výrobním úseku
4. Typ materiálu – kategorie materiálu (např. typ A, B nebo C), ovlivňující jeho specifickou spotřebu

Celkem tedy model pracuje s 5 vstupními neurony, jednou skrytou vrstvou s 15 neurony a jedním výstupním neuronem – tedy celkem 21 neuronů.

Cílová proměnná

- Spotřeba materiálu – výsledné množství spotřebovaných surovin vyjádřené v jednotkách (kilogramech)

7.5 Postup řešení pro konkrétní příklad

Bylo vytvořeno 200 záznamů s následující strukturou:

Generování syntetických dat

1. Inicializace náhodného generátoru

```
set.seed(123)
```

Tímto zajistíme, že generování náhodných hodnot bude opakovatelné, tedy že při každém spuštění budou vytvořena stejná data.

2. Vytvoření vstupních proměnných

```
produkty <- sample(50:500, 200, replace = TRUE)
```

Počet produktů – náhodně generované hodnoty v rozmezí 50 až 500 kusů.

```
teplota <- runif(200, min = 15, max = 35)
```

Teplota – hodnoty z rovnoměrného rozdělení v rozmezí 15 – 35°C.

```
hodiny <- sample(80:200, 200, replace = TRUE)
```

Počet pracovních hodin – náhodný výběr v rozsahu 80 – 200 hodin.

```
typ_mater <- sample(c("A", "B", "C"), 200, replace = TRUE)
```

Typ materiálu – náhodné přiřazení kategorie A, B nebo C.

3. Převedení kategorické proměnné na dummy proměnné

Model `nnet` v R nepracuje přímo s kategoriemi, proto je třeba převést proměnnou `typ_mater` na tzv. dummy (binární) proměnné

```
typ_dummy <- model.matrix(~ typ_mater)[, -1]
```

4. Vygenerování cílové proměnné – spotřeby

```
# Generování cílové proměnné (spotřeba) se záměrně zvolenou závislostí:
spotreba <- 0.05 * produkty + 0.3 * teplota + 0.1 * hodiny +
  ifelse(typ_mater == "A", 20, ifelse(typ_mater == "B", 10,
5)) + rnorm(200, 0, 10)
```

Spotřeba materiálu je vypočtena jako lineární kombinace vstupních proměnných s přidaným šumem (náhodná složka simulující realitu).

5. Sestavení finální datové tabulky

```
data <- data.frame(produkty, teplota, hodiny, typ_dummy, spotreba)
```

Rozdělení dat na trénovací a testovací sadu

Aby bylo možné model otestovat na nezávislých datech, rozdělíme dataset na dvě části v poměru 80:20

```
# Rozdělení na trénovací a testovací data
index <- sample(1:nrow(data), 0.8 * nrow(data))
train <- data[index, ]
test <- data[-index, ]
```

Trénink neuronové sítě v R

Neuronová síť je vytvořena pomocí funkce `nnet()` z knihovny `nnet`:

```
library(nnet)
```

```
model <- nnet(spotreba ~ ., data = train, size = 15, linout = TRUE,  
  decay = 0.1, maxit = 1000)
```

Predikovaná proměnná je spotřeba; size = 15 je počet neuronů ve skryté vrstvě.

Model byl testován na 20 % dat:


```
pred <- predict(model, test)  
MSE <- mean((pred - test$spotreba)^2)  
cat("MSE:", MSE)
```

Výsledek:

MSE: přibližně 108.25 (hodnota se může mírně lišit)

Model neuronové sítě byl otestován na nezávislé testovací množině dat. Pro vyhodnocení predikční schopnosti modelu byl použit ukazatel střední kvadratická chyba (MSE), který vyjadřuje průměrnou odchylku mezi skutečnými a predikovanými hodnotami. Tato hodnota svědčí o relativně dobré přesnosti modelu při predikci spotřeby materiálu. Vzhledem ke generované náhodné složce a charakteru syntetických dat se může výsledek mírně lišit při každém novém spuštění.

Porovnání predikovaných a skutečných hodnot:



Obrázek 4 Porovnání predikovaných hodnot (vlastní zpracování v RStudio)

Graf ukazuje, že většina bodů leží blízko přímky $y = x$, což naznačuje dobrou přesnost modelu.

7.6 Závěr

Navržený model neuronové sítě pro predikci spotřeby materiálu byl úspěšně implementován v prostředí R s využitím knihovny nnet. Výsledky ukazují, že i jednodušší síť se skrytou vrstvou o 15 neuronech dokáže s přijatelnou přesností predikovat spotřebu na základě vstupních proměnných.

Model byl úspěšně otestován na fiktivních datech, kde dosáhl nízké chyby predikce (MSE), což potvrzuje jeho predikční schopnosti. Tato neuronová síť tak představuje efektivní nástroj pro podporu rozhodování ve výrobním podniku. Její praktické nasazení může přispět k optimalizaci plánování, snížení nákladů a efektivnějšímu využívání výrobních zdrojů.

V práci byla současně představena obecnější architektura s vrstvami typu LSTM a Dense, která by mohla být využita zejména při zpracování časově závislých dat. Přestože tento návrh nebyl v rámci případové studie prakticky implementován, představuje směr dalšího rozvoje modelu.

Do budoucna by bylo vhodné model otestovat na reálných datech konkrétního podniku, ale rovněž ho rozšířit o nové prediktory či využít pokročilejší architektury hlubokého učení. Takový přístup by mohl vést k vyšší přesnosti predikce a větší robustnosti modelu v reálných podmínkách.

Tato případová studie tak prokazuje, že neuronové sítě mohou být efektivním nástrojem pro plánování spotřeby materiálu a mohou výrazně přispět k optimalizaci výrobních procesů a nákladového hospodaření podniku.

8 SHRNU TÍ PRAKTICKÉ ČÁSTI

Praktická část práce se zaměřuje na konkrétní aplikaci soft computingových metod v oblasti podnikové ekonomiky.

Využití soft computingových metod v oblasti predikcí

- ekonomických časových řad,
- obchodování na kapitálových trzích,
- ekonomických krizí,
- bankrotu.

Využití soft computingových metod při rozhodování o:

- přijetí klienta,
- koupi podnikového vozidla,
- investičním projektu,
- nákupu výrobních zařízení.

Soft computingové metody se dají využít při zjišťování bonity klienta, odhadu rizika zahraničních investic a také k analýze ziskovosti.

Další možností využití soft computingových metod je hodnocení finančního zdraví podniků.

Finanční zdraví hodnotí i první případová studie, ve které byl v prostředí programu Microsoft Excel vytvořen jednoduchý model fuzzy logiky. K vytvoření takového modelu stačilo jen pár funkcí: SVYHLEDAT, KDYŽ, SUMA, MAX a skalární součin. Bylo vytvořeno několik tabulek, které se propojili již zmíněnými funkcemi. Za pomoci transformační a stavové matice byl vypočten skalární součin, jehož výsledkem bylo hodnota finančního zdraví jednoho z hodnocených podniků. Této hodnotě byla přiřazena jazyková proměnná charakterizující finanční zdraví podniku.

V další případové studii byl za pomoci umělé inteligence vytvořen model neuronové sítě pro predikci spotřeby materiálu. Tento model byl nejprve trénován (učen) a pak testován. Byl vytvořen v jazyku R a následně spuštěn v programu RStudio. Neuronová síť se ukázala jako vhodná pro predikci spotřeby materiálu.

ZÁVĚR

Tato bakalářská práce se zaměřila na analýzu možností využití metod soft computingu v oblasti podnikové ekonomiky a na praktickou demonstraci jejich aplikace prostřednictvím případových studií.

V teoretické části byla provedena rešerše literatury, která představila základní pojmy z oblasti podnikové ekonomiky, manažerského rozhodování, řízení podniku, a především metody soft computingu, jako jsou fuzzy logika, neuronové sítě, genetické a evoluční algoritmy.

Praktická část se věnovala konkrétním možnostem využití soft computingových metod v podnikovém prostředí. Popsány byly různé způsoby aplikace, které se objevily v rámci závěrečných prací jiných autorů – například využití fuzzy logiky při rozhodování o pořízení firemního vozidla nebo hodnocení finančního zdraví podniků pomocí klasických ukazatelů rentability, aktivity, zadluženosti a likvidity.

Na tato témata jsem navázala vlastní případovou studií, v níž jsem porovnávala dvě firmy na základě vypočtených finančních ukazatelů. Využila jsem k tomu program Excel, kde jsem vytvořila jednoduchý model fuzzy logiky, inspirovaný příkladem uvedeným v publikacích pana Dostála. V další případové studii jsem se zaměřila na využití umělé inteligence, a s její pomocí vytvořila model umělé neuronové sítě pro predikci spotřeby materiálu ve výrobním podniku. Podrobně jsem popsala celý postup řešení a prezentovala výsledky modelu.

Výsledky obou studií potvrdily, že metody soft computingu mají značný potenciál při řešení reálných podnikových problémů. Fuzzy logika umožňuje efektivně pracovat s vágními a neúplnými informacemi, což je v manažerské praxi běžné. Neuronové sítě se osvědčily jako účinný nástroj pro prediktivní analýzy, přičemž dosahovaly nízké chyby odhadu.

Soft computing tak představuje důležitý nástroj moderního managementu, který i při práci s nepřesnými nebo neúplnými daty umožňuje získat srozumitelné a prakticky využitelné výsledky. Vzhledem k dynamickému vývoji tržního prostředí a rostoucím nárokům na adaptabilitu podnikových procesů lze očekávat, že význam těchto metod bude i nadále narůstat.

Vypracování této bakalářské práce pro mě představovalo velkou výzvu, která mě zároveň obohatila o řadu nových poznatků. Věřím, že se mi podařilo naplnit cíle, které jsem si na jejím začátku stanovila.

SEZNAM POUŽITÉ LITERATURY

- BĚLOHLÁVEK, Radim; DAUBEN, Joseph W. a KLIR, George J., 2017. *Fuzzy logic and mathematics: a historical perspective*. Oxford: Oxford University Press. ISBN 9780190200015 [cit. 2025-03-20]
- BLAŽEK, Ladislav, 2014. *Management: organizování, rozhodování, ovlivňování*. 2., rozš. vyd. Praha: Grada. ISBN 9788024744292 [cit. 2025-03-13]
- BUGRI, Štefan a PRIBIŠOVÁ, Emília, 2017. *Podniková ekonomika*. Ostrava: KEY Publishing. ISBN 978-80-7418-280-8 [cit. 2025-02-12]
- ČESKO, 2012. Zákon ze dne 22.03.2012, o obchodních společnostech a družstvech (zákon o obchodních korporacích). Online. In: *Sbírka zákonů České republiky*. Částka 34. Dostupné z: <https://www.zakonyprolidi.cz/cs/2012-90#f4590062> [cit. 2025-02-23]
- ČEJKA, Jiří, 2008. *Finanční rozhodování za neurčitosti*. Bakalářská práce. Pardubice: Univerzita Pardubice, Fakulta ekonomicko-správní. Dostupné z: <https://dk.upce.cz/items/ea271fcd-0014-4399-a09f-8993c35e013c> [cit. 2025-05-02]
- DÍAZ-CORTÉS, Margita Arimatea; CUEVAS, Erik a ROJAS, Raúl, 2017. *Engineering applications of soft computing*. Cham, Switzerland: Springer. Online. Dostupné z: <https://doi.org/9783319578132> [cit. 2025-03-23]
- DOSKOČIL, Radek, 2009. *Metodika zjišťování bonity klienta v pojišťovnictví*. Disertační práce. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav informatiky. Dostupná z: <https://dspace.vut.cz/items/73586092-1435-484c-846d-e3bf93d866ad>
- DOSTÁL, Petr, 2015a. *Soft computing v podnikatelství a veřejné správě*. Brno: Akademické nakladatelství CERM. ISBN 978-80-7204-896-0 [cit. 2025-03-20]
- DOSTÁL, Petr, 2015b. *Soft computing v podnikatelství a veřejné správě*. Brno: Akademické nakladatelství CERM. ISBN 978-80-7204-897-7 [cit. 2025-04-18]
- DOSTÁL, Petr, 2017. *Soft computing v podnikatelství a veřejné správě, doplněk*. Brno: Akademické nakladatelství CERM. ISBN 978-80-7204-958-5 [cit. 2025-05-01]
- DYMOWA, Ludmila, 2011. *Soft computing in economics and finance*. Heidelberg: Springer. Online. Dostupné z: <http://www.nsc.ru/interval/Library/ApplBooks/LDymowa-SoftComputing.pdf> [cit. 2025-04-13]

FABOZZI, Frank J, 2015. *Capital markets: institutions, instruments, and risk management*. Fifth edition. Cambridge, Massachusetts: London. ISBN 978-0-262-02948-3. [cit. 2025-03-16]

FOTR, Jiří a ŠVECOVÁ, Lenka, 2022. *Manažerské rozhodování: postupy, metody a nástroje rozhodování v dynamickém a nejistém prostředí*. Čtvrté, přepracované vydání. Jesenice: Ekopress. ISBN 978-80-87865-76-7 [cit. 2025-03-13]

HAND, D. J.; MANNILA, Heikki a SMYTH, Padhraic, 2001. *Principles of data mining. Adaptive computation and machine learning*. Cambridge, Maas.: MIT Press. ISBN 978026256308. Dostupné z: <https://proxy.k.utb.cz/login?url=http://ieeexplore.ieee.org/xpl/bkabstractplus.jsp?bkn=6267275> [cit. 2025-05-02]

HAŠKOVÁ, Simona, 2021. *Aplikace fuzzy přístupu v manažerském rozhodování*. Plzeň: Aleš Čeněk. ISBN 978-80-7380-858-7 [cit. 2025-05-01]

HNILICKÁ, Silvia, 2019. *Stabilita a chaos v makroekonomických modelech*. Diplomová práce. Brno: Masarykova univerzita, Přírodovědecká fakulta, Ústav matematiky a statistiky. Dostupné z: https://is.muni.cz/th/h19xa/Stabilita_a_chaos_v_makroekonomickych_modeloch.pdf [cit. 2025-05-11]

HYNEK, Josef, 2008. *Genetické algoritmy a genetické programování*. Grada. ISBN 978-80-247-2695-3. [cit. 2025-05-01]

JANÍČEK, Přemysl a MAREK, Jiří, 2013. *Expertní inženýrství v systémovém pojetí*. Expert. Praha: Grada. ISBN 978-80-247-4127-7 [cit. 2025-04-15]

JANÍČEK, Přemysl, 2014. *Systémová metodologie: brána do řešení problémů*. Brno: Akademické nakladatelství CERM. ISBN 9788072048878 [cit. 2025-03-22]

JURA, Pavel, 2003. *Základy fuzzy logiky pro řízení a modelování*. Brno: VUT IUM. ISBN 8021422610 [cit. 2025-03-28]

KOŇAŘÍK, Jan, 2024. *Využití fuzzy logiky v rámci finanční analýzy podniku*. Bakalářská práce. Zlín: Univerzita Tomáše Bati ve Zlíně, Fakulta managementu a ekonomiky. Dostupná z: <https://digilib.k.utb.cz/handle/10563/56546> [cit. 2025-04-30]

KORF, M. J. F., 2020. *Optimal Decision Trees in Economics*. Bakalářská práce. Rotterdam: Erasmus Universiteit Rotterdam. Dostupné z:

https://scholar.google.com/scholar?hl=cs&as_sdt=0%2C5&scioq=pokro%C4%8Di%C3%A9+metody+anal%C3%BDz+a+modelov%C3%A1n%C3%AD&q=Optimal+Decision+Trees+in+Economics&btnG= [cit. 2025-05-07]

KNÁPKOVÁ, Adriana, 2024. *Podnikové finance, sbírka příkladů*. Zlín: Univerzita Tomáše Bati ve Zlíně, Fakulta ekonomiky a managementu. Dostupná z: https://moodle.utb.cz/pluginfile.php/1206973/mod_resource/content/1/PPFI1_Sb%C3%A1rka_2024.pdf [cit. 2025-04-11]

KNÁPKOVÁ, Adriana; PAVELKOVÁ, Drahomíra; REMEŠ, Daniel a ŠTEKER, Karel, 2017. *Finanční analýza: komplexní průvodce s příklady*. 3., kompletně aktualizované vydání. Praha: Grada Publishing. ISBN 978-80-271-0563-2. [cit. 2025-03-01]

MADĚRA, Martin, 2024. *Učení umělých neuronových sítí založené na mikrogenetických a genetických algoritmech a ověření na vysokofrekvenčních finančních datech*. Disertační práce. Ostrava: Vysoká škola báňská – Technická univerzita Ostrava, Ekonomická fakulta. Dostupná z: <https://dspace.vsb.cz/handle/10084/155587> [cit. 2025-05-07]

MANDELBROT, Benoit b. a HUDSON, Richard l., 2008. *The (mis)behaviour of markets: a fractal view of risk, ruin, and reward*. Lodon: Profile Books. ISBN 978-1-84668-262-9. [cit. 2025-05-07]

MARTINOVIČOVÁ, Dana; KONEČNÝ, Miloš a VAVŘINA, Jan, 2019. *Úvod do podnikové ekonomiky*. Grada. ISBN 978-80-271-2034-5 [cit. 2025-02-14]

NGUYEN, Trung Thanh, 2011. *Continuous Dynamic Optimisation Using Evolutionary Algorithms*. Disertační práce. Birmingham: University of Birmingham. Dostupná z: <https://etheses.bham.ac.uk/id/eprint/1296/> [cit. 2025-05-14]

NÝVLTOVÁ, Romana a MARINIČ, Pavel, 2010. *Finanční řízení podniku: Moderní metody a trendy*. Grada. ISBN 978-247-3158-2. [cit. 2025-03-15]

PALMER, Samuel, 2019. *Evolutionary Algorithms and Computational Methods for Derivatives Pricing*. Disertační práce. London: University College London. Dostupná z: <https://discovery.ucl.ac.uk/id/eprint/10068568/> [cit. 2025-05-15]

RŮČKOVÁ, Petra, 2021. *Finanční analýza: metody, ukazatele, využití v praxi*. 7. aktualizované vydání. Praha: Grada Publishing. ISBN 978-80-271-3124-2. [cit. 2025-03-09]

SADIL, Vojtěch, 2016. *Využití teorie chaosu a Elliottových vln na finančním trhu*. Diplomová práce. Zlín: Univerzita Tomáše Bati ve Zlíně, Fakulta managementu a ekonomiky. Dostupná z: <https://digilib.k.utb.cz/handle/10563/38025> [cit. 2025-05-14]

SCHEJBALOVÁ, Anna, 2021. *Užití fuzzy logiky v ekonomice podniku*. Bakalářská práce. Pardubice: Univerzita Pardubice, Fakulta ekonomicko-správní. Dostupné z: <https://dk.upce.cz/items/3633c87b-6780-4b12-8c16-86b5efe843a3> [cit. 2025-04-30]

ŠTEKER, Karel a OTRUSINOVÁ, Milana, 2016. *Jak číst účetní výkazy: základy českého účetnictví a výkaznictví*. 2., aktualizované a rozšířené vydání. Praha: Grada Publishing. ISBN 978-80-271-0048-4. [cit. 2025-02-14]

ŠŤASTNÝ, Jiří; POKORNÝ, Martin a MOTYČKA, Arnošt, 2007. *Aplikace umělé inteligence v ekonomické oblasti*. Odborný článek. Brno: Mendelova zemědělská a lesnická univerzita v brně, Provozně ekonomická fakulta, Ústav informatiky. Dostupné z: https://www.researchgate.net/profile/Jiri-Stastny-2/publication/228550789_APLIKACE_UMELE_INTELIGENCE_V_EKONOMICKE_OBLASTI_THE_APPLICATION_OF_ARTIFICIAL_INTELLIGENCE_IN_THE_FIELD_OF_ECONOMICS/links/0c9605294b2584c3db000000/APLIKACE-UMELE-INTELIGENCE-V-EKONOMICKE-OBLASTI-THE-APPLICATION-OF-ARTIFICIAL-INTELLIGENCE-IN-THE-FIELD-OF-ECONOMICS.pdf [cit. 2025-05-14]

ŠULEŘ, Petr, 2023. *Ekonomické nástroje a jejich úloha pro sektorové analýzy s důrazem na sektor dopravy*. Habilitační práce. České Budějovice: Jihočeská univerzita v Českých Budějovicích, Ekonomická fakulta. Dostupné z: https://dspace.jcu.cz/bitstream/handle/20.500.14390/45748/Habilitacni_prace_Petr_Suler.pdf?sequence=1 [cit. 2025-05-14]

ULDRICH, Miloš a JURCZYK, Tomáš, 2014. *Neuronové sítě a jejich využití*. Online, PDF. Dostupné z: http://www.statsoft.cz/file1/PDF/Statsoft_neuronove_site.pdf [cit. 2025-05-11]

VOCHOZKA, Marek a MULAČ, Petr, 2012. *Podniková ekonomika*. Grada. ISBN 978-80-247-4372-1 [cit. 2025-02-13]

VOCHOZKA, Marek; JELÍNEK, Jiří; VÁCHAL, Jan; STRAKOVÁ, Jarmila a STEHEL, Vojtěch, 2017. *Využití neuronových sítí při komplexním hodnocení podniků*. Praha: C. H. Beck. ISBN 9788074006425 [cit. 2025-03-28]

SEZNAM OBRÁZKŮ

Obrázek 1 Schéma biologického neuronu (Sojka et al., 2005).....	36
Obrázek 2 Znázornění chaotického atraktoru (Sojka et al., 2005)	41
Obrázek 3 Vzorec skalárního součinu (snímek obrazovky programu Excel, vlastní zpracování).....	62
Obrázek 4 Porovnání predikovaných hodnot (vlastní zpracování v RStudio).....	70

SEZNAM TABULEK

Tabulka 1 Základní informace o obchodních společnostech (vlastní zpracování dle zákona č.90/2012 Sb. o obchodních společnostech a družstvech)	16
Tabulka 2 Zadání příkladu (vlastní zpracování)	55
Tabulka 3 Vypočtené hodnoty (vlastní zpracování)	56
Tabulka 4 Vypočtené hodnoty ukazatelů (vlastní zpracování)	57
Tabulka 5 Rozsah hodnot a bodové hodnocení rentability vlastního kapitálu	58
Tabulka 6 Rozsah hodnot a bodové hodnocení běžné likvidity (vlastní zpracování)	58
Tabulka 7 Rozsah hodnot a bodové hodnocení celkové zadluženosti (vlastní zpracování)	59
Tabulka 8 Rozsah hodnot a bodové hodnocení obratovosti aktiv (vlastní zpracování)	59
Tabulka 9 Transformační matice (vlastní zpracování)	60
Tabulka 10 Body přiřazené vypočteným hodnotám (vlastní zpracování)	60
Tabulka 11 Stavová matice firmy A (vlastní zpracování)	61
Tabulka 12 Stavová matice firmy B (vlastní zpracování)	61
Tabulka 13 Retransformační matice (vlastní zpracování)	62
Tabulka 14 Výsledek skalárního součinu matic (vlastní zpracování)	63

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

ADAM	adaptive moment estimation
ANN	umělé neuronové sítě
ATD	a tak dále
BL	běžná likvidita
CZ	celková zadluženost
LSTM	long short-term memory
MSE	mean squared error
OA	obrat aktiv
RELU	rectified linear unit
ROE	rentabilita vlastního kapitálu

SEZNAM PŘÍLOH

Příloha P I: Zdrojový kód modelu neuronové sítě pro predikci spotřeby materiálu

Příloha P II: Prompty v umělé inteligenci

PŘÍLOHA P I: ZDROJOVÝ KÓD MODELU NEURONOVÉ SÍTĚ PRO PREDIKCI SPOTŘEBY MATERIÁLU

Zdrojové kódy k návrhu modelu neuronové sítě pro predikci spotřeby materiálu ve výrobním podniku:

```
# Nainstalujte nnet, pokud není nainstalován
if (!require("nnet")) install.packages("nnet")

set.seed(123)

n <- 200 # počet vzorků

# Generování fiktivních vstupních proměnných
produkty <- sample(50:200, n, replace = TRUE)
teplota <- round(rnorm(n, mean = 20, sd = 5), 1)
hodiny <- sample(6:12, n, replace = TRUE)
typ_mater <- sample(c("A", "B", "C"), n, replace = TRUE)

# Kódování typu materiálu jako dummy proměnná
typ_mater_num <- model.matrix(~ typ_mater)[, -1] # vytvoří typ_materB
a typ_materC

# Generování cílové proměnné (spotřeba)
spotreba <- 0.5 * produkty + 2 * teplota + 10 * hodiny +
  ifelse(typ_mater == "A", 100, ifelse(typ_mater == "B", 120, 140)) +
  rnorm(n, 0, 20) # přidán šum

# Datový rámec
data <- data.frame(produkty, teplota, hodiny, typ_mater_num, spotreba)
head(data)

# Rozdělení dat
set.seed(42)
index <- sample(1:n, size = 0.8 * n)
train <- data[index, ]
test <- data[-index, ]

library(nnet)
```

```

# Normalizace vstupů
normalize <- function(x) (x - min(x)) / (max(x) - min(x))
train_norm <- as.data.frame(lapply(train[, -ncol(train)], normalize))
test_norm <- as.data.frame(lapply(test[, -ncol(test)], normalize))

# Přidáme cílovou proměnnou zpět
train_norm$spotreba <- train$spotreba
test_norm$spotreba <- test$spotreba

# Trénink modelu s 15 neurony a regularizací
model <- nnet(spotreba ~ ., data = train_norm, size = 15, linout =
  TRUE,
              decay = 0.1, maxit = 1000, trace = FALSE)

# Predikce
pred <- predict(model, newdata = test_norm)

# Výpočet MSE
mse <- mean((test_norm$spotreba - pred)^2)
cat("Mean Squared Error:", round(mse, 2), "\n")

# Graf
plot(test_norm$spotreba, pred, col = "#0072B2", pch = 19,
      xlab = "Skutečná spotřeba", ylab = "Predikovaná spotřeba",
      main = "Skutečná vs. predikovaná spotřeba materiálu")
abline(0, 1, col = "#D55E00", lwd = 2, lty = 2)
legend("topleft", legend = c("Predikce", "Ideální shoda (y = x)"),
      col = c("#0072B2", "#D55E00"), pch = c(19, NA), lty = c(NA, 2),
      lwd = c(NA, 2))

```

PŘÍLOHA P II: PROMPTY V UMĚLÉ INTELIGENCI

Prompt, který jsem využila v umělé inteligenci pro opravu textu:

Jsi odborník na českou gramatiku a stylistiku, který má bohaté zkušenosti se psaním a opravami odborných textů na akademické půdě. Přepiš můj text, aby byl odbornější a srozumitelnější. Tvoje návrhy nesmí měnit význam původního textu, text můžeš zkrátit o nedůležité informace, podstata textu musí zůstat zachována. Navrhni 2-3 varianty, tyto varianty musí být psány v trpném rodě. Text v kulatých závorkách musí zůstat zachován. Můžeš měnit pouze odstavce a věty mimo kulaté závorky, dodržuj posloupnost informací. Můj text:

Při tvorbě návrhu modelu jsem využila následující prompty:

- vytvoření modelu neuronové sítě pro spotřebu materiálu,
- specifikace, že model je výrobek je tvořen ze tří různých surovin a každá má jinou spotřebu,
- chtěla jsem model popsat a vysvětlit,
- vytvoření umělých dat, která simulují provoz výrobního podniku,
- otestovat model v R pomocí balíčku nnet,
- úprava textu, tak aby byl členěn na zadání, popis problému, cíl,
- doplnění závěru
- porovnání modelů