

UNIVERZITA PARDUBICE
FAKULTA CHEMICKO – TECHNOLOGICKÁ

DIPLOMOVÁ PRÁCE

2019

Bc. Kateřina Joštová

Univerzita Pardubice

Fakulta chemicko – technologická

Hierarchické předpovídání poptávky jako nástroj pro rozhodování podnikového
managementu

Bc. Kateřina Joštová

Diplomová práce

2019

zadání

zadání

Prohlášení autora

Prohlašuji, že jsem tuto práci vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně.

V Pardubicích dne 6.5.2019

Kateřina Joštová

PODĚKOVÁNÍ

Tímto bych chtěla poděkovat svému vedoucímu práce Ing. Michalu Patákovi, Ph.D., za trpělivost, odborné vedení, cenné rady a připomínky, které mi poskytoval v průběhu vypracování diplomové práce. Poděkování patří i obchodnímu řediteli daného potravinářského podniku, který mi poskytl data pro realizaci této práce a věnoval mi svůj čas při pochopení problému, který daný podnik při předpovídání prodejů řeší a jak vůbec samotnou tvorbu předpovědí dělá. V neposlední bych ráda poděkovala i mé rodině, která mi byla během celého studia oporou.

ANOTACE

Diplomová práce se zabývá předpovídáním poptávky ve výrobním podniku. V první části práce je na základě literární rešerše popsán význam a základní principy předpovídání poptávky ve výrobním podniku se zaměřením na možnosti použití moderních metod pro předpovídání poptávky v současném tržním prostředí, a to včetně tzv. hierarchických přístupů k předpovídání poptávky. Ve druhé části práce jsou na základě primárního výzkumu ve vybraném podniku potravinářského průmyslu studovány možnosti použití hierarchických přístupů k předpovídání poptávky za účelem zvýšení přesnosti podnikových předpovědí při plánování prodeje.

KLÍČOVÁ SLOVA

Předpovídání poptávky, hierarchické předpovídání poptávky, plánování prodeje, potravinářský průmysl.

TITLE

Hierarchical demand forecasting as a tool for decision-making in business management

ANNOTATION

This thesis deals with the demand forecasting in the manufacturing company. The first part of the thesis describes the importance and basic principles of the demand forecasting in a manufacturing company. It is based on a literary research and focuses on the possibility of using modern methods for demand forecasting in the current market environment, including the so-called hierarchical approaches to demand forecasting. The second part of the thesis, based on the primary research in the selected food industry, the possibilities of using hierarchical approaches to predict demand in order to increase the accuracy of business forecasting in sales planning are studied.

KEYWORDS

Demand forecasting, hierarchical forecasting approaches.

OBSAH

Seznam ilustrací a tabulek	9
Seznam zkratk a značek	11
Seznam použitých symbolů	12
Úvod.....	13
1 Význam a základní principy předpovídání poptávky ve výrobním podniku	15
1.1 Metody předpovídání poptávky	18
1.1.1 Kvalitativní metody	18
1.1.2 Kvantitativní metody	22
1.1.3 Měření chyby předpovědních modelů	32
1.2 Hierarchické předpovídání poptávky	35
1.2.1 Hierarchické časové řady.....	36
1.2.2 Metody hierarchického předpovídání poptávky	38
2 Hierarchické předpovídání poptávky ve vybraném potravinářském podniku	43
2.1 Použité metody při výzkumu	44
2.2 Výsledky výzkumu a diskuze.....	45
2.2.1 Struktura požadovaných předpovědí a způsob jejich tvorby v podniku	45
2.2.2 Návrh předpovědních modelů.....	48
2.2.3 Analýza přesnosti předpovědních modelů.....	57
Závěr	62
Použitá Literatura.....	65
Přílohy.....	69

SEZNAM ILUSTRACÍ A TABULEK

Obrázek 1 Klasifikace metod pro předpovídání poptávky (Horáková a Kubát 1999, str. 143)	18
Obrázek 2 Graf: vyrovnávání klouzavými průměry pro $k=3$ (Vlčková, Machač, Paták, 2013, str. 150)	25
Obrázek 3 Graf: Holtovo exponenciální vyrovnání pro α a β rovno 0,8 (Vlčková, Machač, Paták, 2013, str. 156)	28
Obrázek 4 Graf: Holtovo exponenciální vyrovnání pro α a β rovno 0,2 (Vlčková, Machač, Paták, 2013, str. 156)	28
Obrázek 5 Graficky zobrazená jednoduchá lineární regrese (Hyndman, 2018, str. 104)	32
Obrázek 6 Příklad hierarchické struktury pro vysvětlení jednotlivých přístupů	36
Obrázek 7 Hierarchická třístupňová struktura prodejů	48
Obrázek 8 Hierarchická struktura časových řad poptávky po sudovém pivu	51
Obrázek 9 Graf časové řady celkových prodejů pro období 2013-2015	51
Obrázek 10 Graf časové řady prodejů v segmentu OZ1 v období 2013-2015	52
Obrázek 11 Graf časové řady prodejů v segmentu OZ2 v období 2013-2015	52
Obrázek 12 Graf časové řady prodejů v segmentu OZ3 v období 2013-2015	53
Obrázek 13 Graf časové řady prodejů v segmentu OZ4 v období 2013-2015	53
Obrázek 14 Graf časové řady prodejů v segmentu OZ5 v období 2013-2015	54
Obrázek 15 Graf časové řady prodejů v segmentu OZ6 v období 2013-2015	54
Obrázek 16 Graf časové řady prodejů v segmentu OZ7 v období 2013-2015	54
Tabulka 1 Optimální váhy pro hierarchickou strukturu z obrázku č. 6 (Hyndman, Athanasopoulos, 2014, str. 44)	41
Tabulka 2 Vzorový příklad pro tvorbu předpovědi poptávky	47
Tabulka 3 Výsledky vzorového příkladu pro tvorbu předpovědi poptávky	48
Tabulka 4 Příklad odstranění problému s řídkou poptávkou	50
Tabulka 5 Použité metody exponenciálního vyrovnávání na střední úrovni hierarchické struktury	55
Tabulka 6 Použité metody exponenciálního vyrovnávání na nejnižší úrovni hierarchické struktury	55
Tabulka 7 Hodnoty ukazatele přesnosti RMSE pro jednotlivé metody a zákaznické segmenty	58

Tabulka 8 Hodnoty ukazatele přesnosti MdAPE pro jednotlivé metody a zákaznické segmenty	59
Tabulka 9 Míra zpřesnění podnikových předpovědí použitím navrhovaných metod.....	59
Tabulka 10 Míra zpřesnění statistických předpovědí použitím hierarchických metod	60

SEZNAM ZKRATEK A ZNAČEK

ACF	Autokorelační funkce
AIC	Akaikeho informační kritérium
BIC	Bayesovo informační kritérium
ČŘ	Časová řada
HF	Hierarchická prognóza
MAD	Střední absolutní chyba
MSE	Střední kvadratická chyba
PACF	Parciální autokorelační funkce
RMSE	Odmocnina ze střední kvadratické chyby
MAPE	Střední absolutní procentuální chyba

SEZNAM POUŽITÝCH SYMBOLŮ

B	operátor zpětného posunutí
C_t	cyklická složka
k	počet parametrů odhadovaného modelu
L	hodnota věrohodnostní funkce
N	velikost výběrového souboru
p_j	průměrná hodnota časové řady
S_t	sezónní složka
T_t	trendová složka
x	prediktor (závisle proměnná)
\bar{y}_t	vyrovnaná hodnota pro časovou řadu
y_t	pozorovaná hodnota časové řady
\tilde{y}_t	odvozená hodnota časové řady
α	koeficient útlumu (vyhlazovací konstanta)
β	konstanta
φ	autoregresní parametry
ε	reziduální složka
θ	parametry klouzavého průměru

ÚVOD

V posledních letech dochází ke změnám tržního prostředí, které sebou přináší nasycený a neucelený trh, vyšší intenzitu konkurence, a tím i významně ovlivňují způsob podnikání. K těmto změnám dochází díky rozvoji nových technologií, deregulaci a globalizaci. Protože roste i konkurence a podobnost výrobků na trhu a na druhou stranu klesá loajalita zákazníků, jsou firmy nuceny neustále hledat nové způsoby, kterými lze získat konkurenční výhodu, aby vytvořili pro zákazníky lepší a hodnotnější nabídku než konkurence. V minulosti byly za klíčové požadavky zákazníka považovány cena a kvalita daného výrobku či služby. V dnešní době je ale hodnota pro zákazníka vnímána jako srovnání užítka získaným z výrobku a vnímanými atributy souvisejícími s náklady na jeho pořízení. (Lošťáková, 2009, str. 11,46). Pro podniky je proto předpovídání poptávky velice důležité, protože jim umožňuje včas reagovat na vznikající situace na trhu (Preclík, 2006, str. 236).

Předpovídání poptávky fascinuje lidi již po tisíce let. V roce 700 před naším letopočtem napsal židovský prorok Izajáš: „Řekněte nám, co má budoucnost – pak budeme vědět, že jste bohové.“ Lidé v minulosti totiž často považovali dobré předpovědi za magické. Ovšem je důležité mít na paměti, že existují prognózy správné a špatné. Názorné příklady velmi špatných podnikových předpovědí uvádí Hyndman (2018, str. 11):

- Myslím, že existuje světový trh asi pro pět počítačů (Předseda IBM, 1943).
- Počítače v budoucnosti možná budou vážit méně než 1,5 tuny (Populární mechanika, 1949).
- Není žádný důvod, proč by někdo chtěl mít doma počítač. (předseda DEC, 1977).

Již z těchto předpovědí je zřejmé, že předpovídání na turbulentních trzích je velmi náročné a společnosti, které to zvládají dobře, mají oproti těm, které to neumí, významnou výhodu. Z toho důvodu si mnoho současných vědeckých prací klade za cíl hledat nové možnosti, které by vedly ke zpřesnění podnikových předpovědí. Jednou z hojně diskutovaných možností je i získávání přesnějších předpovědí pomocí analýzy časových řad na jiném stupni agregace poptávky než vyžaduje předpovídaný problém (Paták, Vlčková, 2013). Takový přístup k předpovídání poptávky, který literatura (např. Hyndman, Athanasopoulos, 2014) označuje jako hierarchické předpovídání, může představovat silný nástroj pro výrobní podniky, protože jim umožňuje zvažovat další faktory, jejichž vliv na poptávku nelze běžnými předpovědními postupy (tj. předpovídáním na jediném stupni agregace poptávky) zachytit a zakomponovat do předpovědního modelu.

Cílem této práce je proto identifikovat možnosti použití hierarchických modelů jako nástroje zvyšování přesnosti předpovědí ve výrobních podnicích. Z tohoto důvodu je v první části práce na základě literární rešerše popsán význam a základní principy předpovídání poptávky ve výrobním podniku se zaměřením na identifikaci metod pro předpovídání poptávky, které lze aplikovat ve výrobních podnicích, a principů hierarchického předpovídání poptávky. Ve druhé části práce jsou prezentovány výsledky primárního výzkumu ve vybraném podniku potravinářského průmyslu, jehož cílem bylo identifikovat požadovanou strukturu předpovědí pro plánování prodeje a proces předpovídání prodeje, navrhnout vhodné hierarchické předpovědní modely a identifikovat míru zpřesnění podnikových předpovědí v závislosti na volbě předpovědního modelu.

1 VÝZNAM A ZÁKLADNÍ PRINCIPY PŘEDPOVÍDÁNÍ POPTÁVKY VE VÝROBNÍM PODNIKU

Existují základní potřeby, jako je například potřeba bydlení, potravy, bezpečí, dále potřeby sociální nebo potřeby jednotlivců – seberealizace nebo poznání. Pokud nejsou potřeby uspokojovány, lidé volí jednu z následujících možností – buď se pokusí potřebu omezit, nebo pro firmy příznivější variantou je, že vyhledají předmět, který jejich potřebu uspokojí. Lidé mají neomezená přání, ale omezené zdroje pro jejich plnění. Proto si vybírají taková přání, která jim za vyložené peníze přinesou co největší uspokojení. Na trhu se nabízejí různé produkty a služby, od těch základních (levnějších) až po ty rozšířenější (dražší), proto podniky vynakládají velké úsilí na to, aby porozuměly potřebám svých zákazníků. Pro pochopení těchto potřeb zákazníků provádějí různé výzkumy. Zajímají se o to, jak zákazníci využívají nejen jejich výrobky, ale i výrobky konkurence, sledují a zjišťují neuspokojené potřeby zákazníků, stejně jako odhadují velikost jejich budoucích potřeb. Postup vedoucí k odhalení budoucí poptávky zákazníků se pak označuje jako předpovídání poptávky. (Kotler, 2007, str. 40-41)

Při předpovídání poptávky je důležité si vyjasnit základní pojmy, mezi které patří tržní poptávka a poptávka po produktech daného podniku. Kotler a Keller (2007, str. 166-167) udávají, že tržní poptávka po nějakém výrobku je celkový objem, který by mohl být koupen definovanou skupinou zákazníků, v definované geografické oblasti, v definovaném časovém období, v definovaném marketingovém prostředí a v definovaném marketingovém programu. Poptávka po produktech daného podniku je podíl podniku na celkové tržní poptávce při alternativních úrovních marketingového úsilí podniku v daném časovém období. Tato poptávka závisí na tom, jak je firma na trhu vnímána – jak jsou vnímány její výrobky, služby, ale i komunikace, ceny a jiné ve vztahu ke konkurenci.

Přestože při řízení výrobního podniku má velký význam předpovídání obou výše uvedených druhů poptávky, poptávka po produktech daného podniku je ze své podstaty mnohem významnější, neboť přímo předurčuje budoucí potřebu podnikových zdrojů a zároveň představuje základní informaci pro řízení všech procesů ve výrobním podniku (Stadtler, Kilger, 2005, str. 139). Pokud nebude uvedeno jinak, pro potřeby této práce bude předpovídání poptávky chápáno jako systematický postup vedoucí k odhadu velikosti poptávky po produktech daného podniku.

Podniky by měli předpovídání poptávky věnovat dostatečné úsilí, protože přesné informace jim pomáhají rychleji reagovat na změny v poptávce zákazníků, zvyšovat dostupnost produktů na trhu, zefektivnit marketingovou komunikaci, ale i zvyšovat dosavadní úroveň zákaznických služeb, a tak získat významnou konkurenční výhodu. (Formánek, 2004)

Hyndman (2018, str. 21 a 22) uvádí, že předvídání poptávky lze popsat jako proces pěti na sebe navazujících kroků. Jedná se o kroky:

- definování předpovědního problému,
- shromažďování informací,
- předběžná analýza dat,
- výběr předpovědní metody,
- vytvoření a ohodnocení předpovědi.

Definování předpovědního problému

Mezi nejtěžší část procesu předvídání poptávky patří právě definování předpovědního problému. Pro jeho vymezení je potřeba dobře pochopit způsob, jakým bude předpověď používána, kdo ji vyžaduje a jak se v určitém podniku vůbec předpověď tvoří. Ten, kdo bude předpověď tvořit, by měl věnovat značný čas i rozhovorům se všemi, kteří se podílejí na sběru dat, ale i s těmi, kdo budou používat předpověď při rozhodování a plánování.

Shromažďování informací

Při předpovídání poptávky dochází ke sběru dvou typů informací – statistických údajů a shromážděné odborné znalosti lidí, kteří data sbírají a používají předpovědi. Podniky se často setkávají s problémem, že nemohou získat dostatek historických dat, aby byly schopni vytvořit dobrý statistický model. V takovém případě lze použít informace od pracovníků z podniku i externích odborníků, kteří mají dostatečné zkušenosti s obsluhovanými trhy.

Předběžná analýza dat

Nashromážděná data pro tvorbu předpovědi poptávky jsou obvykle podrobena předběžné (průzkumné) analýze. Z grafů závislosti velikosti poptávky na čase lze zjistit, zda data obsahují významný trend, sezónní kolísání anebo odlehle hodnoty. Vizualizace vývoje poptávky je důležitá pro výběr vhodné předpovědní metody.

Výběr předpovědní metody

Volba předpovědní metody závisí především na dostupnosti historických dat, na síle vztahů mezi poptávkou a zvažovaných vysvětlujících proměnných, ale také na způsobu, kterým bude získaná předpověď použita. V případech, kdy nejsou dostupné žádné statistické údaje nebo dostupné údaje nejsou relevantní, je nutné použít kvalitativní metody předpovídání, založené na intuici a kvalifikovaném odhadu jednotlivce nebo skupiny odborníků. Naopak kvantitativní metody předpovídání je výhodné použít v případech, kdy jsou k dispozici historická data, a je rozumné předpokládat, že některé aspekty vývoje poptávky v minulosti budou pokračovat i v budoucnosti. Při použití kvantitativních metod je totiž cílem navrhnout předpovědní model, který se opírá o soubor předpokladů z historického vývoje poptávky a zároveň obsahuje jeden nebo více parametrů, které je nutno odhadnout na základě historických dat.

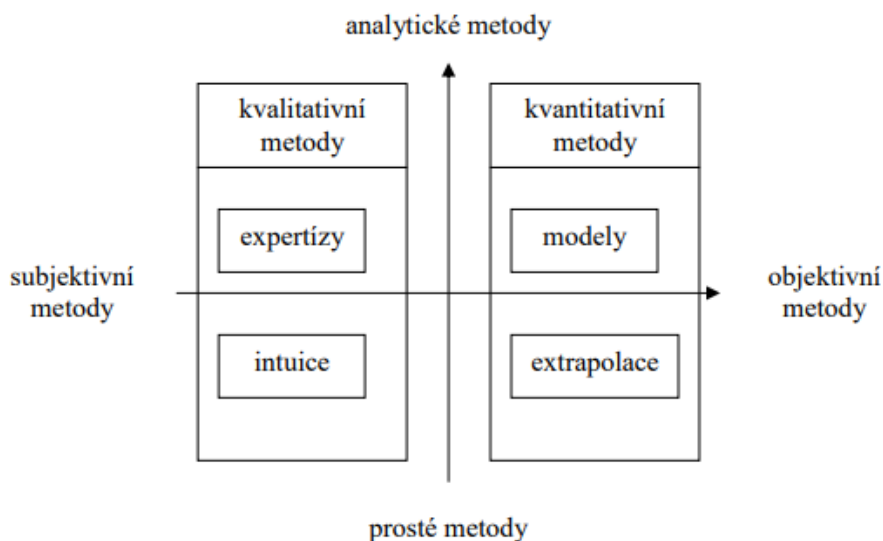
Vytvoření a ohodnocení předpovědi

Aplikací předpovědní metody (resp. extrapolací předpovědního modelu) je získána předpověď poptávky. Po uplynutí časového horizontu předpovědní je vhodné vyhodnotit správnost předpovědi prostřednictvím porovnání předpovězené hodnoty se skutečnou velikostí poptávky. Ex post stanovená právnost předpovědi totiž umožňuje posoudit, do jaké míry byl proces předpovídání poptávky úspěšný a zda je nutné v některých jeho krocích přijmout nápravná opatření.

Vzhledem k cílům práce je obsah dalších kapitol zaměřen na problematiku volby předpovědních metod a principy hierarchických přístupů k předpovídání poptávky.

1.1 Metody předpovídání poptávky

Metody předpovídání poptávky lze podle Horákové a Kubáta (1999, str. 142-143) rozdělit na metody kvalitativní a kvantitativní. Na obr. č. 1 je zobrazen jejich přístup ke klasifikaci metod, založený na dvou základních kritériích (míra analytičnosti a objektivity metod).



Obrázek 1 Klasifikace metod pro předpovídání poptávky (Horáková a Kubát 1999, str. 143)

1.1.1 Kvalitativní metody

Kvalitativní metody předpovídání jsou založeny na úsudku, zkušenostech, intuici a názorech jednotlivce nebo skupiny lidí. Může se jednat o experty v daném oboru, o top management podniku nebo o pracovníky prodeje (Grossová, 2002, str. 149). Výhodou této skupiny metod je, že k ní není potřeba velkého množství historických dat jako v případě metod kvantitativních. Na druhou stranu je jejich velkou nevýhodou subjektivita, což lze zmírnit vhodnou volbou předpovědní metody. Kvalitativní metody se využívají zejména v případech, kdy není dostatek historických dat nebo dokonce tato data nejsou vůbec k dispozici (např. v případě zavádění nového výrobku na trh, při vstupu nového konkurenta na trh nebo při nových a jedinečných tržních podmínkách). Pomocí úsudku lze také upravovat kvantitativní předpovědi, a to zejména v situacích, kdy statistickým modelem nelze postihnout všechny proměnné, které mají vliv na poptávku. (Hyndman, 2018, str. 83)

Mezi kvalitativní metody patří Delfská metoda, metoda historické analogie, brainstorming, panel expertů, šetření záměrů u zákazníků, názory prodejců a další.

1.1.1.1 Delfská metoda

Delfská metoda vychází z předpokladu, že skupinové předpovědi jsou přesnější, než předpovědi tvořené jednotlivcem (Hyndman, 2018, str. 90-93). Metoda je založena na tom, že skupina expertů sdělí svůj názor na vývoj předpovědi a faktory, které ji mohou ovlivnit. Metoda je realizována pomocí dotazování písemnou formou, je tedy anonymní. Po prvním kole dotazování se názory zpracují a výsledek se opět rozešle mezi experty, kteří mohou svoje názory korigovat vzhledem k názorům ostatních expertů nebo si vyžádat další údaje či komentář k ostatním názorům. (Grossová, 2002, str. 149)

Mezi výhody delfské metody patří hlavně to, že lze sestavit skupinu odborníků s různými dovednostmi a odbornými znalostmi z různých vědních oborů. Pomocí konfrontace jejich názorů a možnosti využití zpětné vazby lze postupně upravovat výslednou předpověď. Proto je důležité, aby se jednalo o experty, kteří jsou ochotní spolupracovat. Další výhodou je, že opakovanými koly lze dosáhnout zpřesnění odhadů nejen poptávky, ale i dílčích faktorů, o které jsou tyto odhady opřeny. Za další výhody metody lze považovat možnost zachovat anonymitu odborníků, kteří tím pádem nejsou ovlivňováni politickými ani společenskými tlaky. Jako hlavní nevýhodu lze považovat závislost úspěšnosti celé metody na jednom zvoleném jednotlivci (moderátorovi). Odborníci mezi sebou totiž komunikují nepřímou přes moderátora, který je zodpovědný za veškerou komunikaci, poskytnutí zpětné vazby panelu odborníků i tvorbu závěrečných předpovědí. Časová náročnost této metody může být považována za výhodu i nevýhodu. Výhodou je zejména proto, že pokud je dobře vedena, umožňuje získat názory expertů velmi rychle. Ale na druhou stranu může dojít k jejímu prodloužení z důvodu delší doby zpětné vazby od jednotlivých expertů. (Hyndman, 2018, str. 90-93; Stuchlý, 2001, str. 147 a Grossová, 2004, str. 149)

1.1.1.2 Metoda historické analogie

Metoda historické analogie je založena na zkoumání jevu v širších historických souvislostech a na základě vzájemných podobností dvou nebo více jevů (např. poptávky po několika produktech podniku) lze usuzovat i na jejich podobnost v aspektech dalších.

Nevýhodou této metody je, že její závěry jsou založeny jen na úvaze výzkumníka, který mohl využít abstrakci nebo zobecnění. Abstrakce je založena na odhlížení od vlastností jevu ve prospěch těch, které se zdají být hlavní, s cílem vysvětlit podstatu poptávky po produktech. Zobecnění lze chápat jako rezignování na detaily, které se považují za nepodstatné

a zdůrazňování vlastností, které jsou společné pro širší skupinu poptávaných produktů. (Sedláková, 2014, str. 25 a 26)

Tuto metodu lze uplatnit v případě, že se na trh zavádí nový výrobek. Nezbytnou podmínkou v tomto případě je, že ekonomické a tržní prostředí musí být minimálně v počáteční fázi zavádění nového výrobku podobné tomu prostředí, které odpovídalo analogickému výrobku při jeho zavádění. Tuto metodu nelze tedy použít při zavádění unikátního výrobku. A je třeba mít na paměti, že zcela shodné ekonomické a spotřební podmínky se v podstatě neopakují. (Stuchlý, 2001, str. 147 a Grossová, 2004, str. 150)

1.1.1.3 Brainstorming

Brainstorming se do češtiny překládá jako burza nápadů. Jedná se o expertní metodu, která je založena na vytváření co nejvíce nápadů na dané téma skupinou až dvaceti členů. Celá diskuze se řídí následujícími pravidly (Štědroň, 2012, str. 39,40):

- experti by měli mít podobné vzdělání a společenské postavení,
- diskuze musí probíhat v přátelském a klidném prostředí a jednotlivý účastníci by neměli diskutovat mezi sebou,
- celý úspěch diskuze závisí na formulaci otázek,
- přednesené záznamy se zaznamenávají anonymně,
- z písemného záznamu diskuze provádí jiná skupina odborníků konečné formulace.

Výhodou této metody je rychlost získání názorů odborníků, které lze dosáhnout při správném vedení metody. Díky tomu lze nalézt řešení poměrně rychle a s nízkými náklady. Další výhodou je, že se dosahuje širšího pohledu na problém, atmosféra mezi experty je otevřenější a tým sdílí větší odpovědnost za řešení problému i za jeho výsledek. Pro mnoho firem tato metoda představuje oživení pracovní rutiny a zlepšení pracovního prostředí, proto si také některé firmy nedokáží představit, že by problém řešili pomocí jiné metody. Ani tato metoda není bezchybná. Její nevýhodou je, že účastníci mohou být negativně naladěni, mohou cítit negativní emoce vůči moderátorovi nebo ostatním členům, nebo dokonce i k samotnému tématu a metodě brainstorming. Dalším problémem je, že během sezení mohou zaznít odsudky, které brání tvorbě nápadů. Může se stát i to, že účastníci již nejsou ochotni se dalšího sezení zúčastnit, protože se domnívají, že jich již v minulosti absolvovali mnoho a je na moderátorovi, aby jim opakování vysvětlil. (Štědroň, 2012, str. 40 a Potůček, 2006, str. 17, 18)

1.1.1.4 Panel expertů

Metoda panel expertů je považována jako téměř univerzální způsob tvorby studií, které poskytnou nějakou vizi a/nebo doporučení související s analyzovaným tématem. Panel je většinou tvořen dvanácti až dvaceti osobami, které se 3 až 18 měsíců zabývají budoucností předpovídaného jevu. Časový úsek se volí dle zaměření projektu (např. oblast technologií, zdravotnictví nebo jiné). Experti se po tuto dobu setkávají na předem naplánovaných zasedáních, na kterých posuzují získané poznatky tím způsobem, že oznamují své výsledky pomocí písemné zprávy. Metoda je efektivní při řešení problematiky, která vyžaduje technické znalosti a spolupráci expertů z více různých oborů. (Kotler, 2007, str. 432 a Potůček, 2006, str. 20,21)

Výhodou této metody je, že umožňuje získat názory a posudky od odborníků, které mohou být důležité v nejasnostech spojených s budoucností. Dále i výměna informací a vytváření sítí mezi odborníky s různými vědeckými obory a oblastmi. Důvěryhodnost celého procesu a dosažených výsledků je zajištěna prostřednictvím profilu členů panelu. Další výhodou je snadnost, kterou mohou panely doplňovat další prognostické metody. Nevýhodou je vysoká náročnost na vlastnosti expertů. Nemělo by se jednat zejména o osoby, které nejsou tvůrčí, ochotni spolupracovat nebo dokonce neumí pracovat ve skupinách nebo nejsou ochotni mluvit otevřeně. (Potůček, 2006, str. 26)

1.1.1.5 Výzkum nákupních záměrů u zákazníků a prodejců

Další metodou, jak lze předpovědět poptávku, je provést tržní průzkum, při kterém se měří úmysl trhu, tj. zákazníků nakoupit daný výrobek v určitém časovém úseku. Při této metodě analytici poskytují zákazníkům informace o výrobku a předpokládají, že jim zákazníci budou poskytovat upřímné odpovědi.

Nevýhodou této metody je, že zákazníci mohou říkat analytikům to, co chtějí slyšet, místo toho, aby odpovídali upřímně. Tím mohou být výsledky velmi zavádějící a klamavé. Na druhou stranu, pokud zákazníci poskytují upřímné odpovědi, jedná se o velmi dobrou předpověď. (Kotler a Keller, 2007, str. 171)

1.1.1.6 Názory prodejců

V případě, že je obtížné či nepředstavitelné, aby se firmy ptaly na budoucí poptávku u konečných zákazníků, mohou požádat o tvorbu předpovědí u svých prodejců – obchodních zástupců nebo přímo svých zaměstnanců z prodejního oddělení podniku. Dobrých výsledků

je dosahováno zejména v těch případech, kdy jsou prodejci v přímém kontaktu se zákazníky, znají jejich situaci a očekávaný vývoj.

Nevýhodou této metody je, že prodejci jsou často zaujatí pozorovatelé, mohou být pesimističtí nebo naopak optimističtí, mohou se blížit k extrémům, což může být způsobeno nedávným růstem nebo poklesem prodejů. Prodejci mohou také záměrně prodeje podcenit, aby firma stanovila nižší prodejní kvóty, které jsou základem pro výpočet odměny prodejců. Na druhou stranu, pokud podnik přijme tato rizika, může od prodejců získat velmi užitečné informace, protože jednotlivý prodejci mají obvykle lepší přehled o nastupujících trendech v poptávce než kdokoliv jiný. (Kotler, 2007, str. 432,433 a Grossová, 2006, str. 150)

1.1.2 Kvantitativní metody

Kvantitativní metody jsou založeny na tvorbě předpovědi na základě statistické analýzy historických údajů, jsou tedy na rozdíl od metod kvalitativních založeny na objektivních matematicko-statistických postupech. Přestože se jedná o metody objektivní, nemusí vést k těm nejlepším výsledkům, a to hlavně z důvodu toho, že kvantitativní metody se opírají o předpoklad, že se v budoucnu (času, pro který je předpověď stanovována) nebude měnit dosavadní charakter vývoje poptávky. Tento předpoklad platí spíše v krátkodobém než dlouhodobém horizontu, proto se tyto metody častěji používají při tvorbě krátkodobých a střednědobých předpovědí. Důležité je mít na paměti i fakt, že kvantitativní metody jsou obecně nadřazené metodám kvalitativním (odhadům), a měly by proto sloužit jako výchozí bod pro jakékoliv odhady, u kterých jsou k dispozici historická data. (Hyndman, 2018, str. 83)

Při použití kvantitativních metod se zpravidla modeluje vývoj hodnot časové řady v minulosti a pomocí extrapolace modelu časové řady do budoucnosti se získává požadovaná předpověď (Cipra, 2013, str. 238 a Grossová, 2006, str. 151). Výhodou použití časových řad je jejich snadná grafická interpretace. Mají ovšem i řadu nevýhod, mezi které patří i to, že nejsou schopny odhalit příčiny vznikajících odchylek, pouze je registrují (Kavan, 2002, str. 227 a Cipra, 2013, str. 229,230). Nevýhodou kvantitativních metod je obtížnost nalezení kompromisu mezi jednoduchostí a přesností modelu časových řad při volbě časových bodů pozorování. Problém je v tom, že z hlediska věrnosti by měla mít časová řada více bodů, ale z výpočetního hlediska je lepší, aby nebyly body tak zhuštěné. Problém vzniká ale i v případech, kdy jsou jako časové body pozorování voleny různě dlouhé měsíce, tedy měsíce s různým absolutním počtem dnů nebo počtem pracovních dnů (Štědroň, 2012, str. 51). Grossová (2006, str. 151) však považuje za hlavní nevýhodou

použití časových řad nemožnost určení okamžiku, ve kterém dojde ke změně trendu, např. k nasycení trhu.

Podle Huška (2007) lze kvantitativní metody rozdělit do tří skupin, a to na jednorozměrné, vícerozměrné a ostatní metody prognózování. Jednorozměrné metody předpovídání využívají k tvorbě budoucí (předpovídané) hodnoty časové řady pouze minulé hodnoty bez dalších vysvětlujících proměnných (tj. jedinou vysvětlující proměnnou je čas). Patří mezi ně statistické metody vyrovnávání časových řad pomocí klouzavého průměru (blíže viz kapitola 2.2.1), tradiční dekompozice časových řad na trendovou, sezónní a cyklickou složku (blíže viz kapitola 2.2.2), exponenciální vyrovnávání (blíže viz kapitola 2.2.3) a Box-Jenkinsova metodologie (blíže viz kapitola 2.2.4). Vícerozměrné metody předpovídání vysvětlují proměnné pomocí vztahů mezi minulými hodnotami jedné či více časových řad. Mezi tyto metody patří zejména lineární regrese (viz kapitola 2.2.5), vícerozměrné ARIMA modely, modely vektorových autoregresí (VAR) nebo modely korekce chyb (MKCH). Poslední skupinu tvoří ostatní kvantitativní metody předpovídání, mezi které patří celá řada přístupů, které se tak často nepoužívají, ovšem v určitých případech poskytují velmi dobré výsledky. Patří mezi ně simulační modely, neuronové sítě, genetické algoritmy nebo postupy používané v operačním výzkumu a expertní systémy.

1.1.2.1 Průměr

Průměr lze použít u časových řad, které nevykazují trend ani sezónnost. Jeho výhodou je, že je oproti ostatním metodám velmi snadný, rychle proveditelný, dokáže očišťovat časovou řadu, tj. odstranit z ní negativní dopad variability, ale také to, že pro jeho provedení stačí uchovávat jen data o posledním předvídaném období. Naproti tomu jeho nevýhodou je, že tato metoda není přesná a proto také spíše než k předpovídání slouží jako měřítko pro zjištění vhodnosti daného modelu pro danou časovou řadu. To znamená, že metody předpovídání jsou srovnávány pomocí průměru, abychom zjistili, zda je daná metoda lepší než průměr. Pokud není lepší, jedná se o velmi špatnou metodu, kterou nemá cenu brát při předpovídání v úvahu.

Průměr z n hodnot lze zapsat ve tvaru (1)

$$\bar{y}_t = \frac{y_1 + y_2 + \dots + y_n}{n} \quad (1)$$

kde y_1 je hodnota časové řady na počátku období a y_n je hodnota na konci období. (Hyndman, 2018, str. 47; Gros, 2009, str. 240 a Vlčková, Machač, Paták, 2013, str. 141)

1.1.2.2 Klouzavé průměry

Metoda vyrovnávání pomocí klouzavých průměrů se používá pro časové řady, které nevykazují žádný trend, a je založena na tom, že vyrovnané hodnoty jsou získány jako posloupnost dílčích průměrů, vypočtených za relativně krátké časové úseky několika po sobě jdoucích období. Klouzavý průměr pro období t se vypočte dle následujícího vzorce (2):

$$\bar{y}_t = \frac{y_{t-p} + y_{t-p+1} + \dots + y_{t+p}}{k} \quad (2)$$

Pro $t = 1, 2, \dots, n$ hodnot řady, kde k je počet období z nichž počítáme klouzavé průměry.


U neperiodických časových řad se k , tj. délka klouzavého průměru, nejčastěji volí 3, 5 nebo 7. Nevýhodou této metody je, že nedokáže vyrovnat několik období na začátku a konci časové řady v závislosti na zvolené hodnotě k . Například zvolíme-li $k = 3$, pak první klouzavý průměr spočítáme jako průměr prvních tří hodnot a nově vypočtený průměr (tedy klouzavý) vztáhneme k druhému období (tj. $t = 2$). Další hodnotu klouzavého průměru vypočteme tak, že vypustíme první skutečnou hodnotu y_1 a přidáme další hodnotu v pořadí, tj. y_4 . Při použití $k = 3$ tedy přijdeme jen o první a poslední hodnotu časové řady. V případě použití ale většího množství období (k) bychom přišli o více hodnot, ale výhodou by bylo, že by byla časová řada lépe vyhlazena. (Gros, 2009, str. 242 a Vlčková, Machač, Paták, 2013, str. 149,150)

Z tohoto důvodu není možné použít centrovaný klouzavý průměr pro odhad budoucí hodnoty časové řady. Tento problém lze odstranit tím, že se nepoužívají centrované klouzavé průměry, ale tzv. dopředné klouzavé průměry. V takovém případě se klouzavý průměr pro $k = 3$ vypočte jako v předchozím případě z hodnot za období 1 – 3, ale nevztahuje se k období druhému, ale použije se jako odhad pro období čtvrté. Lze to zapsat pomocí rovnice (3). (Kim, Song, 2007, str. 3012 – 3013)

$$\bar{y}_{t+1} = \bar{y}_t + \frac{1}{k} (y_t - y_{t-k}) \quad (3)$$

kde \bar{y}_t je předpovídaná hodnota pro období t , k je počet období a y_t je pozorovaná hodnota časové řady.

Výhodou vyrovnávání pomocí klouzavých průměrů je, že vyhlazuje největší extrémní časové řady. (Gros, 2009, str. 242) Toto vyhlazení je vidět na následujícím grafu.



Obrázek 2 Graf: vyrovnávání klouzavými průměry pro $k=3$ (vlčková, Machač, Paták, 2013, str. 150)

Výhodou dopředných klouzavých průměrů je, že stejně jako centrované klouzavé průměry dokáží časovou řadu vyhlazovat. Na druhou stranu mají i spoustu nevhod. Jednou z nich je to, že je nelze využít pro časové řady se sezónností nebo s trendem. Dále je velmi obtížné zvolit si délku klouzavého průměru a dalším problémem je, že při výpočtu klouzavého průměru mají všechny hodnoty stejnou váhu. Lepší by bylo, kdyby byly upřednostňovány hodnoty novější před těmi staršími. (Mentzer, Moon, 2005, str. 81-85)

1.1.2.3 Dekompozice časových řad

Časové řady lze obecně dekomponovat na tři základní složky – sezónní S_t , trendovou T_t a cyklickou složku C_t . Samotný rozklad časové řady může být buď aditivní nebo multiplikativní.

Aditivní dekompozice časové řady

Při aditivním rozkladu jsou jednotlivé složky uvažovány ve svých skutečných absolutních hodnotách a jsou měřeny v jednotkách řady y_t . Rozklad lze zapsat rovnicí (4)

$$y_t = S_t + T_t + C_t \quad (4)$$

kde y_t jsou empirické (zjištěné hodnoty pro $t = 1, 2, \dots, n$ časových období), S_t je sezónní složka (periodické změny v časové řadě během 1 kalendářního roku, které se každý rok opakují), T_t je složka trendová (dlouhodobé změny ve smyslu růstu nebo poklesu v průměrné úrovni časové řady) a C_t je složka cyklická (kolísání okolo trendu v důsledku dlouhodobého cyklického vývoje).

Multiplikativní dekompozice časové řady

Při multiplikativním rozkladu j většinou jen trendová složka uvažována ve své absolutní hodnotě a je tedy měřena v jednotkách řady y_t . Ostatní složky časové řady jsou uvažovány v relativních hodnotách vůči trendu a jsou tedy bezrozměrné. Rozklad pomocí multiplikativního modelu lze zapsat rovnicí (5)

$$y_t = S_t \cdot T_t \cdot C_t \quad (5)$$

kde y_t jsou empirické (zjištěné hodnoty pro $t = 1, 2, \dots, n$ časových období), S_t je sezónní složka, T_t je složka trendová a C_t je složka cyklická.

Rozklad časových řad na jednotlivé komponenty se provádí z důvodu lepšího porozumění časovým řadám a ke zlepšení správnosti předpovědi. (Cipra, 2013, str. 232,233, Kavan, 2002, str. 227 a Hyndman, 2018, str. 157)

1.1.2.4 Metody exponenciální vyrovnávání

Metody exponenciálního vyrovnávání byly navrženy koncem 50. let minulého století a vycházejí ze základní úvahy, že nové a staré hodnoty časové řady nemusí mít při výpočtu předpovědi pomocí klouzavého průměru stejný význam. Předpovědi vytvořené pomocí této metody jsou vážené průměry minulých hodnot časové řady, přičemž váhy jednotlivých hodnot se exponenciálně snižují. Čím je tedy hodnota časové řady starší, tím nižší má váhu. Tento fakt je považován za největší výhodu metod exponenciálního vyrovnávání. Mezi nejpoužívanější metody exponenciálního vyrovnávání patří metoda jednoduchého exponenciálního vyrovnávání, Holtova metoda a Winersova metoda, které jsou detailněji popsány v dalším textu. (Hyndman, 2018, str. 183)

Metoda jednoduchého exponenciálního vyrovnávání

Metoda jednoduchého exponenciálního vyrovnávání je nejjednodušší metodou exponenciálního vyrovnávání a je vhodná pro časové řady bez jasného trendu nebo sezónního kolísání. Vyrovnanou hodnotu lze zjistit pomocí rekurentního vzorce (6):

$$\bar{y}_t = (1 - \alpha)\bar{y}_{t-1} + \alpha y_{t-1} \quad (6)$$

kde y_{t-1} je odhad vyrovnané hodnoty v předchozím období, α je koeficient útlumu neboli vyhlazovací konstanta v intervalu $<0;1>$. Čím je vyhlazovací konstanta α menší, tím větší váha se přidává aktuální hodnotě ukazatele y_t a tím menší je vliv starších hodnot časové řady na vyrovnanou hodnotu \bar{y}_t . (Vlčková, Machač, Paták, 2013, str. 150)

Výhodou jednoduchého exponenciálního vyrovnávání je jeho pružnost a možnost volby způsobu vyrovnání podle specifických vlastností dané časové řady. Další velkou výhodou je, že poskytuje celkem rychle spolehlivé prognózy. (Hyndman, 2018, str. 1837; Mentzer, Moon, 2005, str. 86,87 a Vlčková, Machač, Paták, 2013, str. 150,151)

Holtovo exponenciální vyrovnávání

Holtova metoda zobecňuje jednoduché exponenciálního vyrovnávání pro nesezónní časové řady s trendem. (Cipra, 2008, str. 296)

Lze ji popsat ve třech krocích. Nejprve se provede odhad vyrovnané hodnoty pomocí konstanty α podle vztahu (7).

$$L_t = \alpha y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$


Dále se provede odhad změny trendu pomocí konstanty β podle vztahu (8):

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8)$$


kde konstanta β určuje, jakou adaptační váhu přiřazujeme aktuální diferenci ($y_t - y_{t-1}$). Parametr $(1 - \beta)$ určuje váhu pro trendovou složku minulého období. L_t je vyrovnaná hodnota pomocí klouzavého průměru a b_t je trendová složka časové řady. Nakonec získáme vyrovnanou hodnotu \bar{y}_t jako součet obou složek pro dané časové období. A konečný odhad pro následující období m provedeme dle vztahu (9).

$$\bar{y}_{t+m} = L_t + mb_t \quad (9)$$

Parametry konstant α a β se volí podle sledovaného cíle vyrovnání. Pokud volíme vysoké hodnoty, dáváme nejnovějším hodnotám časové řady vysokou váhu a vyrovnané hodnoty lépe kopírují aktuální data. Naopak pokud použijeme hodnoty nízké, budou vyrovnané hodnoty časovou řadu lépe vyhlazovat. Tyto rozdíly lze vidět na grafu č. 3 a 4. (Vlčková, Machač, Paták, 2013, str. 155,156)



Obrázek 3 Graf: Holtovo exponenciální vyrovnání pro α a β rovno 0,8 (Vlčková, Machač, Paták, 2013, str. 156)



Obrázek 4 Graf: Holtovo exponenciální vyrovnání pro α a β rovno 0,2 (Vlčková, Machač, Paták, 2013, str. 156)

Wintersovo exponenciální vyrovnávání

Wintersova metoda exponenciálního vyrovnávání je na rozdíl od výše uvedených metod schopna analyzovat časové řady, které vykazují trend i sezónnost. Používá se ve dvou variantách, a to jako aditivní nebo multiplikační model. Aditivní metoda se používá pro časové řady, jejichž sezónní kolísání představuje konstantní přírůstek, resp. pokles hodnoty časové řady, a multiplikační metoda se používá pro časové řady, u kterých se sezónní složka mění v závislosti na úrovni této řady.

Jedná se o metodu, která vychází z Holtovy metody. V prvním kroku se provede odhad vyrovnané konstanty dle rovnice (10).

$$L_t = \alpha(y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + B_{t-1}) \quad (10)$$

Dále se provede odhad změny trendu de vztahu (11).

$$B_t = \beta(L_t - L_{t-1}) + (1 - \beta)B_{t-1} \quad (11)$$

A dalším krokem je určení sezónní složky dle rovnice (12).

$$S_t = y(y_t - L_t) + (1 - y)S_{t-s} \quad (12)$$

Součtem všech tří složek pro dané časové období, získáme vyrovnanou hodnotu Y_t dle vztahu (13):

$$\bar{y}_{t+m} = L_t + b_t m + S_{t-s+m} \quad (13)$$

kde konstanta β určuje, jakou adaptační váhu přiřazujeme aktuální diferenci ($y_t - y_{t-1}$). Parametr $(1 - \beta)$ určuje váhu pro trendovou složku minulého období. A S_t je sezónní složka v čase t . L_t je vyrovnaná hodnota pomocí klouzavého průměru a b_t je trendová složka časové řady. (Hyndman, 2008, str. 20-26 a Vlčková, Machač, Paták, 2013, str. 155,156)

1.1.2.5 Box-Jenkinsova metodologie

Boxova-Jenkinsova metodologie využívá k analýze časových řad stochastické modely, jako jsou například ARIMA a SARIMA modely. Na rozdíl od předchozích modelů nevyužívá deterministických konstant k vyrovnávání časových řad, ale přistupuje ke každé časové řadě jako k náhodnému (stochastického) procesu. Díky tomu je schopna dobře modelovat časové řady velmi obecných průběhů, které by byly v rámci dekompozičního přístupu nezvladatelné (Cipra, 2013, str. 327). V literatuře (Brockwell a Divis, 2016; Faruk, 2015; Ramos a kol., 2015) lze najít velké množství případů, kdy byla aplikace této metody velmi úspěšná. V praxi se však tato metoda dosud široce nevyužívá, protože vyžaduje analýzu delších úseků časové řady (doporučuje se délka časové řady obsahující alespoň 50 pozorování) a zároveň ji nelze aplikovat jinak než za pomoci výpočetní techniky a pokročilých softwarů, se kterými je třeba i umět pracovat (Cipra, 2013, str. 327).

Aplikace Box-Jenkinsovy metodologie využívá při modelování časových řad několik základních modelů, mezi které patří autoregresní model (AR), model klouzavých průměrů (MA), smíšený model (ARMA), integrovaný autoregresní model klouzavých průměrů (ARIMA) a modely uvažující také sezónní autokorelace (SARIMA).

Všechny výše uvedené modely lze nadefinovat pomocí tzv. operátoru zpětného posunutí B , který umožňuje složitější modely s více zpožděními zapsat v jednodušší a přehlednější formě. Lze ho nadefinovat pro lineární proces dle rovnice (14):

$$By_t = y_{t-1} \quad (14)$$

a obecně dle rovnice (15):

$$B^s y_t = y_{t-s} \quad (15)$$

kde B je operátor zpětného posunutí a y_t je hodnota časové řady.

Autoregresní model AR (p)

Autoregresní model řádu p , označován jako AR (p), předpokládá, že hodnoty časové řady závisí na minulých hodnotách časové řady, tj. že hodnota časové řady v bodě t je tvořena pomocí lineární kombinace minulých hodnot dané časové řady. AR (p) lze pomocí operátoru zpětného posunutí vyjádřit následujícím způsobem (16):

$$(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) y_t = \varepsilon_t \quad (16)$$

kde $\varphi_1, \dots, \varphi_p$ jsou autoregresní parametry, B je operátor zpětného posunutí v daném bodě a ε je reziduální složka. (Cipra, 2013, str. 95, 335)

Model klouzavých průměrů MA (q)

Model klouzavých průměrů řádu q , označován jako MA (q), lze pomocí operátoru zpětného posunutí zapsat následujícím způsobem (17):

$$(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t = y_t \quad (17)$$

Principem modelu klouzavých průměrů není vysvětlit hodnoty časové řady pomocí minulých hodnot dané časové řady, ale pomocí minulé chyby.

Smíšený model ARMA (p,q) model

Smíšený proces ARMA řádu p a q vzniká kombinací autoregresního procesu AR (p) a procesu klouzavých průměrů MA(q). Matematicky lze zapsat vztahem (18).

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (18)$$

Při zápisu modelu pomocí operátoru zpětného posunutí lze ARMA model zapsat také ve tvaru (19):

$$y_t(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (19)$$

kde θ jsou parametry klouzavého průměru a $\theta_q B^q$ operátory klouzavých součtů MA (q). φ jsou autoregresní parametry a $\varphi_p B^p$ je autoregresní operátor AR(p) (Arlt, Arltová, 2007, str. 31 a Cipra, 2013, str. 337,338).

Integrované autoregresní modely klouzavých průměrů ARIMA (p,d,q)

Autoregresní integrovaný proces klouzavých průměrů řádu p,d,q, označovaný jako ARIMA (p,d,q), lze zapsat ve tvaru (20).

$$y_t (1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) (1 - B)^d = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (20)$$

ARIMA modely patří spolu s exponenciálními metodami (zmíněny výše) k nejpoužívanějším přístupům k předpovídání časových řad. Výhodou tohoto modelu je, že na rozdíl od modelu ARMA (p,q) bere ohled i na náhodný trend časové řady. (Hyndman, 2018, str. 221; Stuchlý, 2001, str. 139 a Cipra, 2013, str. 259)

1.1.2.6 Lineární regrese

Lineární regrese umožňuje modelovat lineární vztahy mezi prognózovanou proměnnou y a prediktory $x_1 - x_n$. Model s jediným prediktorem (tj. model jednoduché lineární regrese) lze popsat rovnicí (21):


$$y_t = \beta_0 + \beta_1 x_1 + \varepsilon_t \quad (21)$$

a model vícenásobné lineární regrese, tj. model s více než jedním prediktorem, lze popsat rovnicí (22)

$$y_t = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + \varepsilon_t \quad (22)$$

kde y_t je hodnota vysvětlované proměnné v čase t , β_0 určuje vzdálenost průsečíku regresní přímky s osou y od počátku souřadnic, β_1, \dots, β_n je regresní koeficient pro závisle proměnnou x_1, \dots, x_n a ε_t je reziduální složka v čase t .

Mezi výhody jednoduché lineární regrese patří jednoduchá technika odhadu parametrů předpovědního modelu a jejich jednoznačná interpretace. (Hyndman, 2018, str. 103 a Cipra, 2013, str. 32, 84). Grafické zobrazení použití modelu jednoduché lineární regrese zobrazeno na obrázku č. 5.



Obrázek 5 Graficky zobrazená jednoduchá lineární regrese (Hyndman, 2018, str. 104)

1.1.3 Měření chyby předpovědních modelů

Pokud podnik chce zajistit vysokou úroveň předpovídání, měl by u podnikových předpovědí vyhodnocovat jejich správnost a podle toho adjustovat použité předpovědní modely i způsob jejich použití v budoucnu. Stanovení tzv. chyby předpovědního modelu (při hodnocení předpovědního modelu se nepoužívají měřítka hodnotící správnost předpovědí, ale velikosti dosahované chyby) je zároveň zásadním kritériem výběru vhodného předpovědního modelu a optimalizace jeho parametrů. Při vyhodnocování chyby modelů literatura (Kavan, 2002, str. 243-246) doporučuje použití střední absolutní odchylky, střední kvadratické odchylky, odmocniny ze střední kvadratické chyby a střední absolutní procentuální chybu. Všechna uvedená měřítka jsou podrobněji popsána v následující části textu a u všech platí, že čím je jejich hodnota nižší, tím je daný model přesnější, tj. snahou je navrhnout model, který má co nejnižší hodnotu měřítek chyby předpovědí. (Hyndman, 2018, str. 67)

Střední absolutní chyba (MAD, z anglického Mean Absolute Deviation) lze podle Stuchlého (2001, str. 119) definovat jako průměrnou chybu absolutních rozdílů mezi modelovanými a skutečnými hodnotami časové řady (23):

$$MAD = \frac{1}{k} \sum_{t=1}^k |y_t - \bar{y}_t| \quad (23)$$

kde k je celkový počet období, t je číslo období, y_t je skutečný prodej za dané období, \bar{y}_t je prognóza za období. (Stuchlý, 2001, str. 119 a Kavan, 2002, str. 244)

Střední čtvercová chyba odhadu neboli střední kvadratická odchylka (MSE, z anglického Mean Square Error) se vypočte dle následujícího vzorce (24):

$$MSE = \frac{1}{k} \sum_{t=1}^k (y_t - \bar{y}_t)^2 \quad (24)$$

kde k je celkový počet období, t je číslo období, y_t je skutečný prodej za dané období a \bar{y}_t je prognóza za období.

Odmocnina ze střední kvadratické chyby (RMSE, z anglického Root Mean Square Error) se vypočte dle vzorce (25)

$$RMSE = \sqrt{\frac{1}{k} \sum_{t=1}^k (y_t - \bar{y}_t)^2} \quad (25)$$

kde k je celkový počet období, t je číslo období, y_t je skutečný prodej za dané období a \bar{y}_t je prognóza za období.

Střední absolutní procentuální chyba (MAPE, z anglického Mean Absolute Percentage Error)

$$MAPE = \frac{1}{k} \sum_{t=1}^k \left| \frac{y_t - \bar{y}_t}{y_t} \right| (100 \%) \quad (26)$$

kde k je celkový počet období, t je číslo období, y_t je skutečný prodej za dané období a \bar{y}_t je prognóza za období.

Často se pro hodnocení používá i medián nebo průměr MAPE, který se značí MdAPE a jeho výhodou je, že je odolnější vůči vstupním hodnotám než je MAPE.

Měřítka MAD vyjadřuje průměrnou chybu modelu, má tedy stejný rozměr jako časová řada. Její nevýhoda je, že na rozdíl od měřítek MSE a RMSE méně penalizuje extrémní chyby. Z tohoto důvodu je tato metoda vhodnou mírou chyby předpovědí, pokud náklady spojené s předpovědní chybou rostou lineárně s velikostí chyby. Měřítka MSE udává rozptyl časové řady, který se nepodařilo předpovědním modelem vysvětlit, a je nejpoužívanějším kritériem při měření přesnosti předpovědních modelů. Aby bylo možné vyjádřit chybu předpovědi bezrozměrně (relativním způsobem), používá se měřítko MAPE, které lze jako jediné použít pro porovnávání přesnosti modelů aplikovaných na různých časových řadách. (Stuchlý, 2001, str. 119, Kavan, 2002, str. 244 a Mentzer, Moon, 2005, str. 43,49,53-54)

Kromě výše zmíněných statistických měřítek, lze využít i Akaikeho a Bayesovo informační kritérium (popsány níže), které vyjadřují závislost shody modelu s daty na počtu

parametrů. Tyto kritéria na rozdíl od výše uvedených měřítek penalizují složité modely o velkém počtu parametrů, které mohou danou časovou řadu lépe modelovat, ale zároveň také ztrácí predikční sílu. (Soukup, 2010, str. 96)

Akaikeho informační kritérium

Akaikeho informační kritérium AIC (Akaike Information Crterion) představil již v roce 1974 Hiroutuga Akaik. Lze ho vypočítat pomocí následující rovnice (27):

$$AIC = 2k - 2 \ln L \quad (27)$$

kde k je počet parametrů odhadovaného modelu a L je hodnota věrohodnostní funkce příslušného modelu pro výběrová data.

Ze vzorce (27) je zřejmé, že kritérium AIC zohledňuje pravděpodobnost, že je daný model vhodný pro analyzovaná data, a zároveň, jak již bylo zmíněno dříve, penalizuje složité modely o velkém počtu parametrů. Snahou je vybrat co nejjednodušší model, který stačí k popisu reality na základě analyzovaných dat. Proto jsou při použití AIC kritéria složitější modely penalizovány navyšováním AIC za každý další parametr o dvě jednotky. (Soukup, 2010, str. 96)

Bayesovo informační kritérium

Bayesovo informační kritérium bylo představeno v roce 1978 Schwarzem, proto se v některé literatuře objevuje jako Schwarzovo kritérium (SBC). Toto kritérium je dáno vzorcem (28):

$$BIC = \ln(MSE) + k \cdot \frac{\ln(n)}{n} \quad (28)$$

kde k je počet parametrů předpovědní metody, n je velikost výběrového souboru, tj. počet úseků časové řady, které byly vyrovnány předpovědní metodou a MSE je střední kvadratická odchylka (viz vzorek 24) (Soukup, 2010, str. 97, Abu Bakar, 2015, str. 148 a Cipra, 2013, str. 127).

Pro Akaikeho informační kritérium AIC a Bayosovské informační kritérium BIC platí, že čím menší je jejich hodnota, tím je daný model lepší. Jedná se o kritéria, která jsou využívána zejména u optimalizace počtu parametrů ve složitějších modelech typu vícenásobné regrese nebo ARIMA. Použití těchto kritérií je hledání kompromisu mezi

složitostí modelu a jeho přesností, přičemž kritérium BIC preferuje jednodušší modely a kritérium AIC modely složitější. (Soukup, 2010, str. 95,98 a Hušek, 2007, str. 63)

Při zjišťování nejvhodnějšího modelu může dojít k situaci, kdy dle jednoho kritéria může být nejvhodnější model X a dle jiného kritéria model Y. V takovém případě je třeba, aby analytik přihlédl k jiným metodám, jako jsou například celkové testy modelů nebo diagnostika reziduí. (Soukup, 2010, str. 98 – 99)

1.2 Hierarchické předpovídání poptávky

Předpovídání poptávky je výchozím bodem pro rozhodování podnikového managementu. Protože rozhodování na různých řídicích úsecích v rámci jednoho podniku vyžaduje odlišné informační vstupy, nevyužívá se v podniku jediná předpověď poptávky, ale celý systém podnikových předpovědí na různých stupních agregace poptávky (Flidner, 1999, str. 1134). Předpovídání na nízkém stupni agregace poptávky (např. na úrovni jednotlivých produktů, kterých jsou v podniku stovky či tisíce) ovšem vyžaduje analýzu velkého množství dat, které může neúměrně navyšovat pracnost předpovídání i náklady s ním spojené. Proto podniky využívají tzv. hierarchických přístupů k předpovídání, při kterém jsou předpovědi odvozovány na jiném stupni agregace, než je objekt předpovídání. Předpovědi na požadovaném stupni agregace jsou pak dopočítány jednoduchým algoritmem některé z hierarchických metod. V uvedeném příkladu by významně snížilo pracnost i náklady na předpovídání seskupení jednotlivých položek produktů do skupin (např. produktových řad). Předpovídání na vyšším stupni agregace by zároveň mohlo výsledné předpovědi zpřesnit v důsledku snížení variability časových řad na úrovni produktových skupin.

Jednotlivé položky produktů se v podniku seskupují nejčastěji podle typu produktu, geografické oblasti nebo zákazníka (Rostami-Tabar, Babai, Ducq, Syntetos, 2015, str. 298). V případě použití geografické agregační proměnné lze celkovou poptávku rozdělit např. podle země odbytu nebo spádových oblastí používaných distribučních kanálů (Hyndman, 2018, str. 297), v případě zákaznické agregační proměnné lze celkovou poptávku rozdělit podle segmentů trhu, které jsou obvykle stanoveny na základě druhu potřeby zákazníka nebo jeho demografických charakteristik (Kotler a Keller, 2007, str. 269).

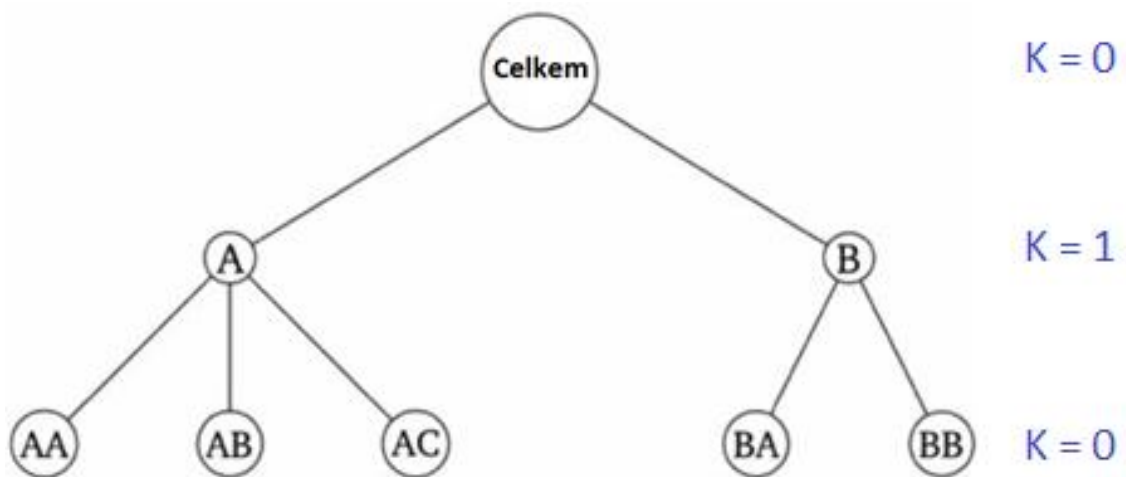
Hierarchické předpovídání (HF) je tedy centralizovaný prognostický přístup schopný uspokojit rozmanitost požadavků jednotlivých manažerů podniku. Je totiž schopen poskytnout informace pro podporu rozhodování mnoha uživatelům, z nichž každý pochází z různé úrovně řízení či organizační funkce. Vedle schopnosti poskytovat informace o předpovědích

pro mnoho uživatelů je potenciál HF důležitý ze dvou dalších důvodů. Za prvé má schopnost zlepšit přesnost podnikových předpovědí a podpořit tím lepší rozhodování. A zadruhé je HF v podnicích snižuje velikost předpovědního problému. S ohledem na současné vysoké požadavky zákazníků na šíři produktových řad jsou systémy HF využívány v průmyslu mnohem intenzivněji, neboť firmy jsou nuceny zejména snížit velikost předpovědního problému (Fliedner, 2001, str. 5).

1.2.1 Hierarchické časové řady

Časové řady poptávky stejně jako samotné produkty podniku mohou být agregovány podle různých proměnných (viz výše uvedené příklady agregačních proměnných). Postupný rozklad celkové časové řady poptávky lze popsat hierarchickou strukturou (tj. hierarchií) časových řad a dílčí časové řady v rámci definované struktury se pak nazývají hierarchické časové řady.

Diagram na obrázku č. 6 znázorňuje příklad hierarchické struktury se dvěma úrovněmi ($K = 2$) a třinácti hierarchickými časovými řadami, znázorněnými pomocí uzlů ($n = 13$). Na vrcholu hierarchie ($K = 0$) je uzel „Celkem“, který je rozdělen do čtyř kategorií: A, B, C a D ($K = 1$; $n_1 = 4$). Každá z těchto kategorií je následně rozdělena do dalších dvou kategorií: AA, AB, BA, BB, CA, CB, DA a DB ($K = 2$; $n_2 = 8$). (Mirčetić, Nikolić, Stojanović, Maslaric, 2017, str. 194,195)



Obrázek 6 6 Příklad hierarchické struktury pro vysvětlení jednotlivých přístupů

(Hyndman, Athanosopoulos, 2014, str. 42)

Pro hodnoty časových řad ve všech pozorovaných i předpovídaných obdobích musí platit vztahy (29 – 33)

$$AA + AB = A \quad (29)$$

$$BA + BB = B \quad (30)$$

$$CA + CB = C \quad (31)$$

$$DA + DB = D \quad (32)$$

$$A + B + C + D = \text{Celkem} \quad (33)$$

Pokud předpovídáme časové řady pro každý uzel nezávisle, předpovědi nemusejí splňovat všechny nebo některé z výše uvedených vztahů (28 – 32). Tj. pokud sečteme jednotlivé předpovědi pro uzly A, B, C a D, součet nemusí odpovídat předpovědi pro uzel „Celkem“. Tento rozdíl může způsobit nejasnosti při samotném rozhodování (např. kolik zásob nebo kolik peněz je potřeba rozdělit mezi jednotlivé divize společnosti). Hierarchické metody předpovídání jsou navrženy tak, aby byly předpovědi na všech uzlech hierarchie ve vzájemném souladu (tj. aby platily všechny výše uvedené součtové vztahy). (Hyndman, Athanasopoulos, 2014, str. 41)

Pro jakékoli období časové řady t lze hodnoty časové řady na nižších úrovních hierarchie agregovat do úrovně vyšších. Tento jev lze matematicky zapsat pomocí tzv. součtové matice, která převádí součtové vztahy (29-33) do maticového zápisu agregace (34).

$$\underbrace{\begin{bmatrix} y_t \\ y_{A,t} \\ y_{B,t} \\ y_{C,t} \\ y_{D,t} \\ y_{AA,t} \\ y_{AB,t} \\ y_{BA,t} \\ y_{BB,t} \\ y_{CA,t} \\ y_{CB,t} \\ y_{DA,t} \\ y_{DB,t} \end{bmatrix}}_{\mathbf{y}_t} = \underbrace{\begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}}_S \cdot \underbrace{\begin{bmatrix} y_{AA,t} \\ y_{AB,t} \\ y_{BA,t} \\ y_{BB,t} \\ y_{CA,t} \\ y_{CB,t} \\ y_{DA,t} \\ y_{DB,t} \end{bmatrix}}_{\mathbf{y}_{k,t}} \quad (34)$$

kde y_t je vektor všech pozorování v čase t , S je souhrnná matice $m \times n$, která určuje, jak jsou agregovány spodní úrovně, y_{kt} je vektor všech pozorování v dolní úrovni hierarchické struktury v čase t . (Hyndman, 2018, str. 298,299 a Mirčetić, Nikolić, Stojanović, Maslaric, 2017, str. 195)

1.2.2 Metody hierarchického předpovídání poptávky

V současné době se využívají nejčastěji tři základní přístupy pro tvorbu hierarchických předpovědí. Přístup „bottom-up“ neboli zdola nahoru, přístup „top-down“ neboli shora dolů nebo „middle-out“, což je kombinace obou uvedených přístupů (Rostamii-Tabar, Babai, Ducq, Syntetos, 2015, str. 297). V roce 2011 Hyndman a jeho kolektiv při svém výzkumu navrhli ještě metodu čtvrtou. Jde o metodu tzv. optimálního sladění (Hyndman, Athanosopoulos, 2014, str. 44). Principy, výhody a nevýhody použití jednotlivých přístupů budou vysvětleny na hierarchické struktuře, kterou zobrazuje obrázek č.6.

1.2.2.1 Přístup bottom-up

Přístup bottom-up („zdola nahoru“) spočívá v tom, že se nejprve vytvářejí nezávislé předpovědi pro každou časovou řadu na nejnižší úrovni hierarchie. V příkladu na obr. 6 je jedná o uzly AA, AB, AC, BA a BB. Tyto předpovědi se následně agregují pro vyšší úrovně hierarchie. V příkladu na obr. 6 by se tedy součtem předpovědí na uzlech AA, AB a AC vytvořila předpověď pro uzel A, dále pak součtem předpovědí na uzlech BA a BB by se vytvořila předpověď pro uzel B a nakonec součtem předpovědí na uzlech A a B by se vytvořila konečná předpověď pro uzel „celkem“. (Hyndman, Athanasopoulos, 2014, str. 43 a Pennings, van Dalen, 2017, str. 412).

Pro přístup bottom-up lze uplatnit maticový zápis (35), kde \tilde{y} je n - dimenzionální vektor koherentních prognóz h předchozího kroku a h je horizont prognóz.

$$\begin{bmatrix} \tilde{y}_h \\ \tilde{y}_{A,h} \\ \tilde{y}_{B,h} \\ \tilde{y}_{AA,h} \\ \tilde{y}_{AB,h} \\ \tilde{y}_{AC,h} \\ \tilde{y}_{BA,h} \\ \tilde{y}_{BB,h} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \hat{y}_{AA,h} \\ \hat{y}_{AB,h} \\ \hat{y}_{AC,h} \\ \hat{y}_{BA,h} \\ \hat{y}_{BB,h} \end{bmatrix} \cdot \quad (35)$$

Výhodou tohoto přístupu je, že se předpovědi tvoří pouze na nejnižší úrovni hierarchie, a proto kvůli agregaci ke ztrátě informací nedochází. Na druhou stranu časové řady na nejnižší úrovni hierarchie mohou být obtížně předvídatelné. (Hyndman, 2018, str. 307 a Hyndman, Ahmed, Athanasopoulos, 2011, str. 2 580).

1.2.2.2 Přístup top-down

Přístup top-down („shora dolů“) je založen na tvorbě předpovědi pro nejvyšší úroveň hierarchie (v případě na obrázku č. 6 se jedná o uzel „celkem“), která se následně rozdělí na jednotlivé předpovědi na nižších úrovních hierarchie. Existuje několik způsobů, jak tuto předpověď rozdělit. (Hyndman, Athanasopoulos, 2014, str. 43).

Nejčastější metodou pro stanovení koeficientů p_j je metoda průměrných historických poměrů, kterou lze vyjádřit rovnicí (36)

$$p_j = \frac{1}{T} \sum_{t=1}^T \frac{y_{j,t}}{y_t} \quad (36)$$

kde každý koeficient p_j zachycuje průměru historických průměrů hodnotu časové řady nejnižší úrovně $y_{j,t}$ ve vztahu k hodnotě celkové agregované řady y_t .

Druhým způsobem pro stanovení koeficientů p_j je výpočet poměrů historických průměrů (37)

$$p_j = \sum_{t=1}^T \frac{\frac{y_{j,t}}{T}}{\frac{y_t}{T}} \quad (37)$$

kde každý koeficient p_j představuje průměrnou historickou hodnotu časové řady na nejnižší úrovni hierarchie $y_{j,t}$ ve vztahu k průměrné hodnotě celkové agregované řady y_t . (Hyndman, 2018, str. 308).

Použití průměrných poměrů lze ilustrovat na následujícím příkladu. Pokud byl průměrný podíl poptávky v uzlu A na celkové poptávce 65 %, odvodila by se předpověď pro uzel A tak, že by se celková předpověď vynásobila koeficientem p_j 0,65. Na předpověď pro uzel B by tedy zbývalo 35 %, odvodila by se tedy vynásobením celkové předpovědi koeficientem p_j 0,35. Obrovskou nevýhodou tohoto přístupu je skutečnost, že poměry p_j nezohledňují možné změny poměrů v čase. Proto přístup shora dolů, který je založen na historických poměrech, má tendenci vytvářet méně přesné prognózy na nižších úrovních hierarchie než přístupy zdola nahoru. (Hyndman, Athanasopoulos, 2014, str. 43). Další nevýhodou je i ztráta informací v důsledku agregace. S využitím historických poměrů

nedokážeme zachytit a využít výhody jednotlivých úrovních, jako je například časová dynamika (sezónnost) nebo mimořádné události. Naopak výhodou této metody je její nízká pracnost, protože stačí vytvářet předpovědi pouze pro jedinou, a to nejvyšší úroveň hierarchie (Hyndman, 2018, str. 307).

1.2.2.3 Přístup middle-out

Třetím přístupem, který je v praxi široce používán, je přístup middle-out („od středu ven“). Při aplikaci tohoto přístupu je vybrána vhodná střední úroveň hierarchie, na které jsou vytvářeny předpovědi (v příkladu na obrázku č. 8 by se jednalo o uzly A a B). Předpovědi na vyšších úrovních hierarchie jsou agregovány podle principu „bottom-up“ a pro předpovědi na nižších úrovních hierarchie jsou uplatňovány principy top-down (Hyndman, Athanasopoulos, 2014, str. 43).

1.2.2.4 Přístup optimal reconciliation

Až donedávna byly výše uvedené přístupy („bottom-up“, „top-down“ a „middle-out“) jedinými používanými hierarchickými metodami (Hyndman, Athanasopoulos, 2014, str. 43). V roce 2011 však Hyndman, Ahmed, Athanasopoulos a Shang představili přístup „optimal reconciliation“, který používá předpovědi na všech úrovních hierarchie, pouze je vhodným způsobem upraví tak, aby byly ve vzájemném souladu. Do češtiny lze proto tento přístup přeložit jako přístup optimálního sladění.

Principem optimálního přístupu je vytvoření navzájem nezávislých předpovědí pro všechny časové řady, tj. pro všechny uzly v hierarchii. V navazujícím kroku se stanoví pro každý uzel hierarchie vektor optimálních vah na základě lineární regrese. Použité váhy lze považovat za optimální, pokud je střední kvadratická chyba (rozdíl mezi nezávislými a konečnými předpověďmi) minimální. V posledním kroku je každá konečná předpověď vypočtena jako skalární součin vektoru příslušných optimálních vah a vektoru nezávislých předpovědí. Vztah pro odvození konečných předpovědí lze vyjádřit maticovým zápisem (38). (Hyndman, 2018, str. 315)

$$y_h = S(S^T S)^{-1} S^T \tilde{y}_h \quad (38)$$

kde y_h je vektor konečných (optimálně sladěných) předpovědí, S je součtová matice (její podoba závisí na hierarchické struktuře poptávky), součin $S(S^T S)^{-1} S^T$ odpovídá matici vah a \tilde{y}_h je vektor nezávislých předpovědí.

Výhodou optimálního sladění je, že hodnoty v matici vah nejsou závislé na vstupních datech, ale pouze na hierarchické struktuře poptávky, protože součtová matice pro danou hierarchickou strukturu je vždy stejná. V tabulce č. 1 je příklad matice vah, které odpovídají hierarchické struktuře z obrázku č. 6.

Tabulka 1 Optimální váhy pro hierarchickou strukturu z obrázku č. 6 (Hyndman, Athanasopoulos, 2014, str. 44)

Odvozené předpovědi	Základní předpovědi							
	Celkem	A	B	AA	AB	AC	BA	BB
Celkem	0,586	0,310	0,276	0,103	0,103	0,103	0,138	0,138
A	0,310	0,517	-0,207	0,172	0,172	0,172	-0,103	-0,103
B	0,276	-0,207	0,483	-0,069	-0,069	-0,069	0,241	0,241
AA	0,103	0,172	-0,069	0,724	-0,276	-0,276	-0,034	-0,034
AB	0,103	0,172	-0,069	-0,276	0,724	-0,276	-0,034	-0,034
AC	0,103	0,172	-0,069	-0,276	-0,276	0,724	-0,034	-0,034
BA	0,138	-0,103	0,241	-0,034	-0,034	-0,034	0,621	0,379
BB	0,138	-0,103	0,241	-0,034	-0,034	-0,034	-0,379	0,621

Na výpočet konečné předpovědi lze také pohlížet jako na vážený průměr všech nezávislých předpovědí. Jako příklad lze uvést výpočet konečné předpovědi pro uzel A (39), při kterém musí být použity váhy z druhého řádku Tabulky 1. (Hyndman, Athanasopoulos, 2014, str. 44)

$$y_A = 0,310 \tilde{y}_{Celkem} + 0,517\tilde{y}_A - 0,207\tilde{y}_B + 0,172\tilde{y}_{AA} + 0,172\tilde{y}_{AB} + 0,172\tilde{y}_{AC} - 0,103\tilde{y}_{BA} - 0,103\tilde{y}_{BB} \quad (39)$$

Obrovskou výhodou přístupu optimálního sladění je využití všech dostupných informací z celé hierarchické struktury časových řad. Díky tomu je možné odhalit vlastnosti časových řad, které jsou na různých úrovních agregace pro uživatele skryté, avšak důležité při modelování a předpovídání. Výhodou této metody je také to, že optimální váhy jsou závislé jen na hierarchické struktuře. Nejsou tedy závislé na skutečných zjištěných datech, proto je stačí pro danou hierarchii vypočítat jen jednou a následně už jen znovu použít. Další výhodou je to, že pokud jsou nezávislé předpovědi nezkreslené, metoda poskytuje nestranné předpovědi (nenadhodnocuje ani nepodhodnocuje výsledné předpovědi na určitých stupních hierarchie). Právě z tohoto důvodu metoda optimálního sladění často poskytuje

přesnější předpovědi než metody založené na principech „top-down“, „bottom-up“ a middle-out“. (Hyndman, 2018, str. 315; Hyndman, Athanasopoulos, 2014, str. 44).

2 HIERARCHICKÉ PŘEDPOVÍDÁNÍ POPTÁVKY VE VYBRANÉM POTRAVINÁŘSKÉM PODNIKU

Přesné a spolehlivé předpovědi jsou klíčové pro přijetí správných rozhodnutí v podniku, ale pro jejich tvorbu může podnik vybírat ze široké škály předpovědních metod. Přínosem hierarchických přístupů k předpovídání poptávky je zohlednění celé hierarchické struktury poptávky, a proto aplikace hierarchických modelů vede ke vzájemně sladěným předpovědím na různých stupních agregace poptávky. Vystává však otázka, zda by postupy hierarchického předpovídání nemohly být také použity ke zvyšování přesnosti podnikových předpovědí, které se jinak vytvářejí pouze na jediném stupni agregace poptávky.

Pro řešení této výzkumné otázky byl navržen výzkum, jehož hlavním cílem bylo identifikovat možnosti zvýšení přesnosti předpovědi prodejů ve vybraném výrobním podniku pomocí hierarchického předpovídání. Tento hlavní cíl byl dále rozdělen na tři dílčí cíle:

- identifikovat požadovanou strukturu předpovědí a proces předvídání poptávky ve vybraném podniku,
- navrhnout hierarchické předpovědní modely pro zvýšení přesnosti podnikové předpovědi a
- identifikovat míru zpřesnění podnikových předpovědí v závislosti na volbě předpovědního modelu.

Podnik, který byl pro výzkum vybrán, je český pivovar, který vyrábí jak lahvové, tak i sudové pivo. V současné době je na území České republiky 11 velkopivovarů, 33 pivovarů a nespočet minipivovarů. Mezi velkopivovary patří například pivovar Staropramen, Budějovický Budvar, Starobrno, Krušovice, Plzeňský Prazdroj nebo také pivovar Svijany a Ostrava. Mezi pivovary se pak řadí Městský pivovar Nová Paka, pivovar Černá Hora, rodinný pivovar Bernard, pivovar Primátor, Pardubický pivovar nebo pivovar Rychtář. Konkurence na českém trhu s pivem je tedy poměrně veliká, aniž bychom diskutovali konkurenční tlak od zahraničních pivovarů, který rovněž není zanedbatelný. V dnešní době je většina pivovarů živena převážně exportem piva do zahraničí, protože české pivo je ve světě hodně známé a oblíbené. Tak jako ale české pivovary exportují své produkty do zahraničí, tak se i v českých ochodech objevují zahraniční piva, jako jsou například holandský Heineken a Amstel, belgická Stella nebo irský Guinness. Vzhledem k zaměření práce, která obsahuje citlivé podnikové informace a při jejím vzniku byla analyzována citlivá podniková data, nelze vybraný podnik detailněji specifikovat.

2.1 Použité metody při výzkumu

Pro splnění prvního dílčího cíle (identifikovat požadovanou strukturu předpovědi a proces předvídání poptávky ve vybraném podniku) byl realizován kvalitativní výzkum ve vybraném podniku formou polostrukturovaného rozhovoru s obchodním ředitelem.

K naplnění dalších dvou dílčích cílů (navrhnout hierarchické předpovědní modely pro zvýšení přesnosti podnikové předpovědi a identifikovat míru zpřesnění podnikových předpovědí v závislosti na volbě předpovědního modelu) byla použita analýza časových řad prodejů sudového piva v letech 2013 – 2016. Údaje o minulých prodejích, které podnik poskytl k analýze, tvořily časové řady měsíčních prodejů sudového piva (v hl) u jednotlivých zákazníků podniku s informací o tom, který z obchodních zástupců daného zákazníka obsluhuje (celkem 7 obchodních zástupců a 1 777 zákazníků). Při analýze časových řad byly použity běžné statistické nástroje v prostředí softwaru IBM SPSS Statistics (verze 24), a to zejména modul *Time Series Modeler*, který umožňuje automatickou volbu vhodné předpovědní metody a optimalizaci parametrů předpovědních modelů pomocí minimalizace informačního kritéria BIC (viz kapitola 1.1.3.). Při automatizované volbě předpovědní metody byly zvažovány pouze metody exponenciálního vyrovnávání, a to konkrétně jednoduché exponenciální vyrovnávání, jednoduché exponenciální vyrovnávání se sezónní složkou, Holtovo exponenciální vyrovnávání a Wintersovo exponenciální vyrovnávání s aditivní nebo multiplikační sezónní složkou. Principy uvedených metod jsou detailně popsány v kapitole 1.1.2.4.

Pro identifikaci míry zpřesnění podnikových předpovědí poskytl podnik vlastní předpovědi poptávky, které byly v podniku vytvářeny vždy s ročním předstihem v požadované struktuře. Pro tuto analýzu byla použita tzv. metoda cross-validace předpovědního modelu, při které je analyzovaná časová řada rozdělena na 2 části. První část časové řady (tzv. trénovací část) slouží k nastavení parametrů předpovědního modelu a jejich optimalizace, zatímco druhá, obvykle kratší část časové řady (tzv. testovací část) je předpovídána a získané předpovědi jsou porovnávány se skutečností. Díky tomu lze docílit objektivního posouzení přesnosti předpovědního modelu v testovací části časové řady. (Xu, Fu Goodarzi a spol, 2018, str. 74) Jako trénovací část bylo zvoleno období časové řady od ledna 2013 do prosince 2015, testovací část pak bylo zvoleno poslední období časové řady od ledna 2016 do prosince 2016. Přesnost navržených předpovědních modelů v testovací části časové řady byla porovnávána pomocí ukazatelů chyby předpovědi RMSE a MdAPE (v případech, kdy bylo nutné odstranit závislost ukazatele na měřítku dat). Principy

a výpočtové vzorce pro oba ukazatele jsou součástí kap. 1.2.3. Míra zpřesnění předpovědi byla měřena pomocí procenta zpřesnění předpovědi, které lze vyjádřit pomocí výpočtového vzorce (40):

$$\% \text{ zlepšení} = \frac{RMSE_{\text{referenčního modelu}} - RMSE_{\text{navrženého modelu}}}{RMSE_{\text{referenčního modelu}}} \quad (40)$$

kde $RMSE_{\text{referenčního modelu}}$ je v daném případě RMSE předpovědi prodeje tvořené podnikem a $RMSE_{\text{navrženého modelu}}$ je RMSE dané předpovědi prodeje tvořené statistickými metodami, tj. nezávislé předpovědi a modely bottom up, top down a model optimálního sladění.

2.2 Výsledky výzkumu a diskuze

V následující části textu jsou podrobně popsány a diskutovány výsledky výzkumu podle tří výše zmíněných dílčích cílů výzkumu.

2.2.1 Struktura požadovaných předpovědí a způsob jejich tvorby v podniku

Charakter poptávky po sudovém pivu, ale i způsob jeho výroby vyžaduje v podniku roční plánování prodeje s informací o sezónních výkyvech v jednotlivých měsících. Zákazníky, kteří v podniku poptávají sudové pivo (ČR), podnik segmentuje do sedmi geografických regionů, přičemž každý z těchto regionů je obsluhován jedním obchodním zástupcem. Protože plán prodeje slouží nejen pro tvorbu dalších plánů podniku (např. plán výroby a nákupu), ale zároveň je na něj navázáno hodnocení a odměňování obchodních zástupců, podnik plánuje na konci každého roku měsíční prodeje sudového piva (v hl) v jednotlivých segmentech zákazníků pro celý následující rok. Východiskem pro tvorbu plánu prodeje je předpověď měsíční poptávky po sudovém pivu na stejném stupni agregace poptávky, jakou používá plán prodeje.

Při předpovídání poptávky v různých geografických segmentech s různým počtem zákazníků jsou zvažovány interní i externí faktory, které mohou mít významný dopad na velikost poptávky po sudovém pivu.

Za nejvýznamnější interní faktor lze považovat strukturální změny v segmentech zákazníků. Může nastat situace, kdy v určitém segmentu přibude větší množství nových zákazníků nebo velký zákazník, jehož obsluha je časově náročnější. Takovou situaci podnik v minulosti řešil buď přesunem vybraných zákazníků do segmentu jiného obchodního zástupce (obvykle sousedního regionu) nebo zvýšil počet obchodních zástupců, a tedy i počet segmentů. Existuje i spousta externích faktorů, které podnik které není schopen příliš ovlivnit a je dobré, aby je při předpovídání zvažoval. V poslední době dochází k růstu prodeje

piva lahvového a poklesům u piva sudového. Je to způsobeno zejména ze tří legislativních důvodů, které nastaly v minulých třech letech. Prvním z těchto důvodů bylo zavedení elektronické evidence tržeb (EET). Pro spoustu malých podniků bylo nereálné pořídit si vybavení (pokladnu apod.) za několik tisíc korun českých, a také dokud nebylo EET zavedeno, některé menší podniky část svých tržeb nepřiznávali, a tím pádem z nich ani neodváděli daň. Protože ale povinnost zavedení EET padla na všechny podniky bez ohledu na jejich velikost, velká část podniků byla zavřena. Druhým důvodem, proč dochází k poklesu prodeje sudového piva, je zákaz kouření v restauracích. Před tímto zákazem měl každý volbu, zda jít do kuřácké nebo nekuřácké restaurace, avšak zejména ve větších městech. Ale na vesnicích či menších městech se často nacházel jen jeden podnik (hospoda, restaurace apod.), ve kterých lidé konzumovali nejen sudové pivo, ale také tabákové výrobky. Po přijetí zákona o zákazu kouření se lidem nelíbilo, že museli chodit kouřit ven, proto jich hodně do těchto podniků přestalo chodit, což opět vedlo ke snížení jejich poptávky po sudovém pivu a v horších případech až k uzavření restauračních zařízení. Posledním důvodem poklesu poptávky po sudovém pivu je úbytek heren a kasin, ke které došlo po významných regulačních opatřeních státu v této oblasti podnikání.

I přes uvedené externí faktory ale nedochází k poklesu prodeje celkového objemu piva (v sudech i lahvích), jen se mění jejich poměrné zastoupení. Přibližně před deseti lety byl poměr konzumace sudového a lahvového piva přibližně 6:4 a dnes je to z výše zmíněných důvodů naopak, tedy 4:6.

Vybraný podnik kombinuje kvalitativní a kvantitativní metody předpovídání. K tvorbě předpovědí využívá historická data prodeje, která extrapoluje do budoucnosti a podle dostupných informací o trhu s pivem je kvalitativně upravuje. Podnik obvykle vychází pouze z jediné hodnoty minulého prodeje, který byl realizován v daném měsíci u daného obchodního zástupce v bezprostředně předcházejícím roce (tzv. jednoduchá extrapolace). Tuto hodnotu následně vynásobí očekávaným procentem navýšení/snížení poptávky, a stanoví tak konečnou předpověď poptávky v požadované struktuře. Při volbě velikosti procenta navýšení/snížení poptávky se opírá o fakt, že v posledních letech dochází k poklesu prodeje sudového piva a naopak k nárůstu prodeje piva lahvového, není tedy spravedlivé požadovat po obchodních zástupcích, kteří mají na starosti prodej právě sudového piva, stejné procento navýšení poptávky jako po obchodních zástupcích, kteří mají na starosti prodej piva lahvového. Z tohoto důvodu nastavuje různá procenta u obchodních zástupců, kteří mají na starosti prodej sudového piva, a u obchodních zástupců, kteří naopak mají na starosti

prodej lahvového piva. Avšak ani obchodní zástupci, kteří obsluhují trhy se stejným typem piva, nemají přidělené stejné procento navýšení/snížení poptávky. Záleží to totiž na síle daného regionu. Někteří obchodní zástupci mají, co se plochy týče, malý region, ale co se týče zákazníků, velmi silný region. Obchodní zástupce, který obsluhuje větší počet zákazníků na menší ploše, totiž stihne během kratší doby osobně komunikovat s větším počtem zákazníků. Obchodní zástupci také obsluhují regiony s různým potenciálem. Navýšení prodeje se očekává zejména u malých regionů, ke kterým se proto váže větší procento navýšení prodeje. Čím je tedy region větší (dle prodaných hl), tím dostane menší procento nárůstu. Jednotlivá procenta jsou tedy u regionů rozdílná, ale co se týče celkového nárůstu v hl, tak jsou si velmi podobná.

Další faktor, který ovlivňuje způsob tvorby podnikových předpovědí, je přesun zákazníků mezi segmenty nebo i situace, kdy obchodní zástupce o nějakého zákazníka přijde anebo mu přibude nový. V případě přesunu zákazníka pod jiného obchodního zástupce dochází k navýšení poptávky u jednoho obchodního zástupce, ale k poklesu poptávky u obchodního zástupce, pod nímž byl daný zákazník do té doby. Pro lepší pochopení je celý postup znázorněn v Tabulce 2 na příkladu dvou obchodních zástupců s pěti zákazníky

Tabulka 2 Vzorový příklad pro tvorbu předpovědi poptávky

	Zákazník	Prodeje [hl] v lednu 2015
Obchodní zástupce 1	1	54,5
	2	12,4
	3	5,7
	Celkem	72,6
Obchodní zástupce 2	11	35,9
	12	19,7
	Celkem	55,6

V případě, kdyby se předpokládal nárůst prodeje o 5 % u obou obchodních zástupců, tvořila by se výsledná předpověď poptávky pouhým zvýšením celkových prodeje o daných 5 %. V případě, že by došlo k přesunu zákazníka č. 2, musely by se hodnoty minulých prodeje u tohoto zákazníka nejdříve přiřadit k obchodnímu zástupci č. 2 a navýšit předpověď

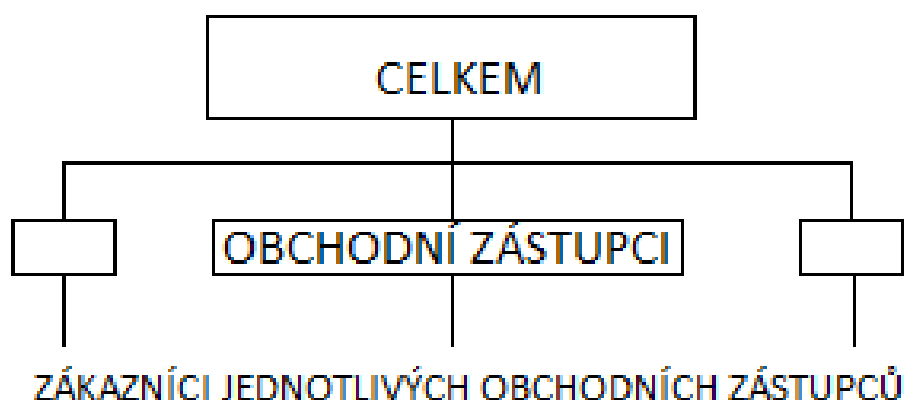
až po této úpravě. Výsledné hodnoty předpovědí v obou situacích (bez přesunu a s přesunem zákazníka) zachycuje Tabulka 3.

Tabulka 3 Výsledky vzorového příkladu pro tvorbu předpovědi poptávky

	Zákazník	Prodeje [hl] v lednu 2015	Předpověď poptávky [hl] pro leden 2016	
			Bez přesunu zákazníka	S přesunem zákazníka
Obchodní zástupce 1	1	54,5	57,2	
	2	12,4	13,0	/
	3	5,7	6,0	
	Celkem	72,6	76,2	63,2
Obchodní zástupce 2	11	35,9	37,7	
	12	19,7	20,7	
	2	12,4	/	13,0
	Celkem	55,6	58,4	71,4
Celková poptávka		128,2	134,6	

2.2.2 Návrh předpovědních modelů

Při návrhu předpovědních modelů se vycházelo z dat o prodejech v letech 2013 – 2015. Před samotnou analýzou časových řad bylo potřeba získaná data z podniku upravit za účelem získání časových řad prodejů na různých stupních zákaznické agregace. Cílem úpravy dat bylo získat časové řady pro hierarchickou strukturu znázorněnou na obrázku 7.



Obrázek 7 Hierarchická třístupňová struktura prodejů

2.2.2.1 Příprava dat

Nejprve byla data o minulých prodeích sudového piva upravena tak, aby byla získána datová matice časových řad měsíčních prodejů ve sledovaném období pro celkový prodej sudového piva, dále pro zákaznické segmenty (tj. prodeje jednotlivých obchodních zástupců) a nakonec pro jednotlivé zákazníky. Tato matice ovšem musela být kvůli přechodům zákazníků mezi obchodním zástupci, duplicitě zákazníků a řídké poptávce u některých zákazníků dále upravena.

Podnik občas přerozděluje prodeje jednoho zákazníky mezi několik obchodních zástupců (společná zainteresovanost na realizovaném prodeji). Tato duplicita byla odstraněna tak, že takovýto zákazník byl u každého obchodního zástupce překódován. Tj, pokud například zákazník 825 spadal pod obchodního zástupce 1, 3 a 7, byly mu přiděleny nové kódy, a to 82501 pro obchodního zástupce 1, 82503 pro obchodního zástupce 3 a 82507 pro obchodního zástupce 7. Pomocí překódování byl také odstraněn problém s přechodem zákazníků pod jiného obchodního zástupce. V tomto případě byl zákazník nahrazen jiným kódem. Tj, pokud například zákazník 825 do roku 2015 spadal pod obchodního zástupce 1 a od tohoto roku již pod obchodního zástupce 2, byl mu přidělen zcela nový kód například 956.

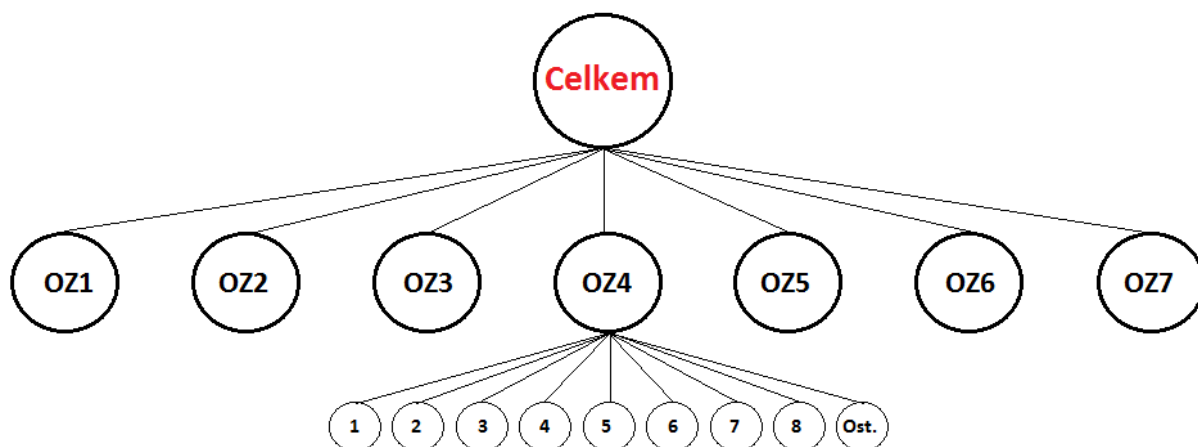
Další úprava byla provedena kvůli řídké poptávce u malých zákazníků podniku. Tato úprava byla provedena pomocí semiagregace, při které jsou zákazníci s řídkou poptávkou slučováni do segmentu ostatních zákazníků, na který je pohlíženo jako na jediného zákazníka (Paták, Vlčková, 2014, str. 338). Aby touto semiagregací nebyli do nového segmentu zbytečně zahrnuti noví zákazníci podniku, agregováni byli pouze zákazníci s řídkou poptávkou v posledním sledovaném roce trénovací části časových řad. U každého obchodního zástupce byl tedy vytvořen fiktivní zákazník (Ostatní_OZ). Tomuto zákazníkovi byly přiřazeny prodeje od všech zákazníků daného obchodního zástupce, kteří nerealizovali žádný prodej v roce 2015 ve více než 30 % pozorování časové řady (čtyři měsíce). Příklad tohoto sloučení je uveden v Tabulce 5, ve které přeškrtnuté objemy prodejů odpovídají zákazníkům, kteří byli právě kvůli řídké poptávce v roce 2015 sloučeni do skupiny zákazníků s názvem Ostatní_OZ1.

Tabulka 4 Příklad odstranění problému s řídkou poptávkou

Měsíc	Zákazník 1	Zákazník 2	Zákazník 3	Zákazník 4	Zákazník 5	Ostatní_OZ1
1	0	28,6	1,3	1,5	4,5	= 0 + 1,5
2	0	15,7	0	1,5	2,2	= 0 + 1,5
3	1	12,5	3,3	0	4,4	= 1 + 0
4	0	11,9	2,4	1,7	3,9	= 0 + 1,7
5	0	24,6	0	0	5,7	= 0 + 0
6	0	28,4	2,4	2,2	6,8	= 0 + 2,2
7	0	31,9	1,8	0	5,3	= 0 + 0
8	1,6	18,5	2,5	0	5,2	= 1,6 + 0
9	0,5	12,7	0	1,8	3,5	= 0,5 + 1,8
10	0	37,1	0,9	0	1,8	= 0 + 0
11	0	21,5	0	1,7	1,4	= 0 + 1,7
12	0,8	19,7	0,8	2,1	1,0	= 0,8 + 2,1

Z tabulky je vidět, že podle tohoto příkladu došlo u obchodního zástupce 1 ke změně v počtu zákazníků, a to z pěti zákazníků na čtyři zákazníky. Zákazníci č. 1 a č. 5 byly sloučeny a vytvořili nového zákazníka (Ostatní_OZ1). Časové řady prodejů u ostatních zákazníků (č. 2,3 a 4) zůstaly nezměněny.

Po přípravě dat vznikla hierarchická struktura časových řad, která je uvedena na obrázku č. 8. První úroveň s označením Celkem zahrnuje poptávku po sudovém pivu za všechny zákazníky podniku. Druhou úroveň tvoří poptávka po sudovém pivu v sedmi zákaznických segmentech podle obchodních zástupců OZ1 až OZ7, kteří dané segmenty obsluhují. Nakonec nejnižší úroveň hierarchické struktury představuje poptávku jednotlivých zákazníků (včetně těch, kteří byli při přípravě dat fiktivně vytvořeni). Vzhledem k velkému počtu zákazníků je struktura poptávky na nejnižší úrovni hierarchie zobrazena pouze v segmentu obchodního zástupce OZ4.

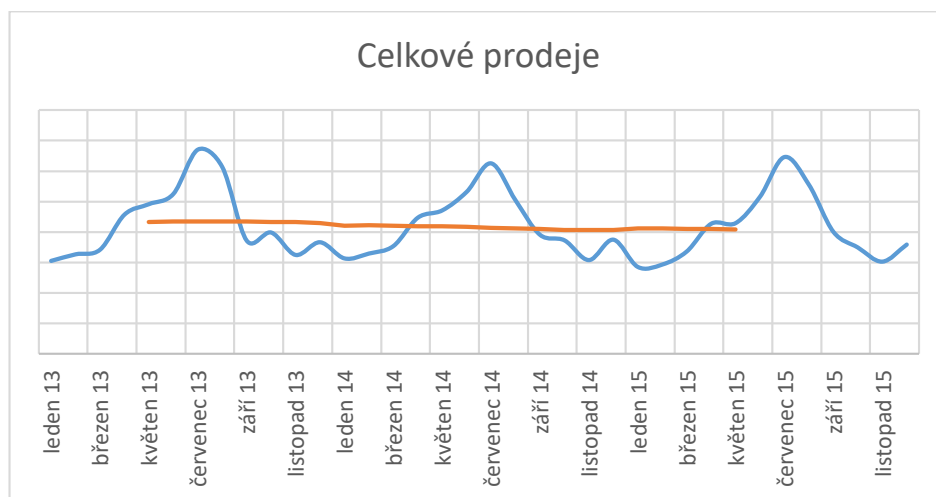


Obrázek 8 Hierarchická struktura časových řad poptávky po sudovém pivu

2.2.2.2 Analýza časových řad


Prvním krokem analýzy časových řad bylo vytvoření spojnicových grafů u všech časových řad, což poskytlo základní přehled o tom, zda se ve vývoji poptávky po sudovém pivu vyskytuje trend, sezónní kolísání nebo jiné, náhodné výkyvy. Celkové prodeje byly analyzovány metodou Wintersova exponenciálního vyrovnávání s aditivní sezónní složkou. Graf časové řady celkových prodejů je na obrázku 9, kde červeně je zobrazen i centrováný klouzavý průměr o délce 12, který byl zvolen proto, že odstraní sezónní výkyvy v časových řadách. Z časové řady klouzavých průměrů vyplývá, že poptávka po sudovém pivu vykazuje výrazné sezónní kolísání (přibližně do letních prázdnin prodeje rostou, v červenci a srpnu jsou největší a od září do ledna opět klesají). Dále je z grafu viditelný i mírně klesající trend, který je způsobem zejména úbytkem prodeje sudového piva na úkor piva lahvového (viz kapitola 2.2.1.1.).

Obrázek 9 Graf časové řady celkových prodejů pro období 2013-2015



V dalším kroku byla provedena analýza časových řad na druhé úrovni agregace, tj. na úrovni zákaznických segmentů. Spojnicové grafy uvedených časových řad jsou součástí obrázků 10 – 16.


Obrázek 10 Graf časové řady prodejů v segmentu OZ1 v období 2013-2015



Z grafu časové řady prodejů v prvním segmentu zákazníků je vidět, že obsahuje proměnlivý trend. V roce 2013 bylo v tomto segmentu dosaženo průměrných prodejů, v roce 2014 prodeje až do července rostly a poté opět klesaly. V roce 2015 pak byly prodeje opět největší v červenci a poté klesaly.


Naproti tomu u druhého segmentu zákazníků nelze pozorovat žádný významný trend ani sezónnost. Největší prodeje tohoto segmentu zákazníků byly v červnu 2013, červenci 2014 a v roce 2015 dokonce v dubnu.

Obrázek 11 Graf časové řady prodejů v segmentu OZ2 v období 2013-2015




U segmentů zákazníků 3 až 7, jejichž grafy jsou uvedeny níže, se u všech vyskytuje sezónnost s největšími prodeji v červenci každého roku. Nejnížší prodeje se u jednotlivých zástupců liší, ale u všech jsou v zimních měsících.


Obrázek 12 Graf časové řady prodejů v segmentu OZ3 v období 2013-2015




Obrázek 13 Graf časové řady prodejů v segmentu OZ4 v období 2013-2015




Obrázek 14 Graf časové řady prodejů v segmentu OZ5 v období 2013-2015



Obrázek 15 Graf časové řady prodejů v segmentu OZ6 v období 2013-2015



Obrázek 16 Graf časové řady prodejů v segmentu OZ7 v období 2013-2015



Z grafů je vidět, že charakteru časové řady celkových prodejů se nejvíce přibližují časové řady segmentů č.3, č. 4 a č. 7 a naopak nejméně časová řada segmentu č. 1. Při volbě vhodné metody exponenciálního vyrovnávání na základě minimalizace kritéria BIC byla ve všech případech použita metoda exponenciálního vyrovnávání se sezónní složkou (aditivní nebo multiplikatívni sezónnost), v některých případech byla zvažována i existence trendové složky v časových řadách. Konkrétní použité metody jsou uvedeny v tabulce 5.

Tabulka 5 Použité metody exponenciálního vyrovnávání na střední úrovni hierarchické struktury

Segment	Metoda
Obchodní zástupce 1	Jednoduché exponenciální vyrovnávání se sezónní složkou
Obchodní zástupce 2	Jednoduché exponenciální vyrovnávání se sezónní složkou
Obchodní zástupce 3	Jednoduché exponenciální vyrovnávání se sezónní složkou
Obchodní zástupce 4	Wintersovo exponenciální vyrovnávání – aditivní model
Obchodní zástupce 5	Wintersovo exponenciální vyrovnávání – aditivní model
Obchodní zástupce 6	Jednoduché exponenciální vyrovnávání se sezónní složkou
Obchodní zástupce 7	Wintersovo exponenciální vyrovnávání – multiplikatívni model

Na nejnižší úrovni hierarchické struktury se pak vyskytovalo celkem 370 časových řad prodejů u jednotlivých zákazníků, pro jejichž předpovídání byly použity metody uvedeny v tabulce 6. Z důvodu velkého množství zákazníků jsou ovšem uvedeny jen četnosti použití daných metod, nikoliv jejich využití pro konkrétní zákazníky.

Tabulka 6 Použité metody exponenciálního vyrovnávání na nejnižší úrovni hierarchické struktury

Metoda	Počet výskytů
Jednoduché exponenciální vyrovnávání	1
Jednoduché exponenciální vyrovnávání se sezónní složkou	242
Wintersovo exponenciální vyrovnávání – aditivní model	118
Wintersovo exponenciální vyrovnávání – multiplikatívni model	9

2.2.2.3 Hierarchické předpovědní modely

Vývoj časových řad na všech úrovních hierarchické struktury poptávky byl pro testovanou část časové řady (rok 2016) předpovídán výše vybranou metodou exponenciálního vyrovnávání. Pokud vyšla jakákoliv předpověď pro rok 2016 záporně, byla její hodnota vždy nahrazena nulou, protože poptávka nemůže nabývat záporných hodnot.

Tímto způsobem byly vytvořeny tzv. nezávislé předpovědi, které byly dále využívány v hierarchických modelech. Nezávislé předpovědi na úrovni zákaznických segmentů byly použity také jako referenční metoda (model nezávislých předpovědí). Nezávislé předpovědi na rozdíl od podnikových předpovědí totiž využívají exponenciální vyrovnávání při předpovídání časových řad, ale na druhou stranu nevyužívají hierarchických přístupů k předpovídání poptávky. Porovnáním nezávislých předpovědí s předpověďmi získanými hierarchickými modely lze pak kvantifikovat přínos hierarchických přístupů k předpovídání poptávky v podniku (míru zpřesnění statistických předpovědí).

Hierarchické předpovědi poptávky byly tvořeny pouze pro testovací část časových řad na požadovaném stupni agregace poptávky – tj. měsíční poptávka po sudovém pivu v jednotlivých zákaznických segmentech pro rok 2016.

Model bottom-up

Při využití modelu bottom-up, se nejprve vytvářejí předpovědi pro nejnižší úroveň hierarchické struktury (v našem případě pro jednotlivé zákazníky) a z těchto předpovědí se dále tvoří předpovědi agregované poptávky (tedy pro jednotlivé obchodní zástupce). Celková předpověď poptávky pro daného obchodního zástupce se tedy vypočte jako suma všech předpovědí pro všechny jeho zákazníky, dle následujícího vzorce (41)

$$\tilde{y}_{OZx} = \sum_1^n \bar{y}_n \quad (41)$$

kde \tilde{y}_{OZx} je předpověď pro obchodního zástupce x a \bar{y}_n jsou nezávislé předpovědi všech zákazníků daného obchodního zástupce.

Pro názornou ukázkou u obchodního zástupce 4 z hierarchické struktury na obrázku 7, se celková předpověď určí následujícím způsobem

$$\tilde{y}_{OZ4} = \bar{y}_{Zák1} + \bar{y}_{Zák2} + \bar{y}_{Zák3} + \bar{y}_{Zák4} + \bar{y}_{Zák5} + \bar{y}_{Zák6} + \bar{y}_{Zák7} + \bar{y}_{Zák8} + \bar{y}_{Ost.} \quad (42)$$

kde \tilde{y}_{OZ4} je předpověď pro obchodního zástupce 4, $\bar{y}_{Zák1} - \bar{y}_{Ost.}$ jsou nezávislé předpovědi pro zákazníky 1 až Ostatní obchodního zástupce 4. Výsledné předpovědi prodeje na dané úrovni agregace jsou uvedeny v příloze č. 2 této práce.

Model top-down

U aplikace modelu top-down byly nejprve určeny poměry historických průměrů dle vzorce (43):

$$p_j = \sum_{t=1}^T \frac{\frac{y_{j,t}}{T}}{\frac{y_t}{T}} \quad (43)$$

kde každý koeficient p_j představuje průměrnou historickou hodnotu časové řady na nejnižší úrovni hierarchie $y_{j,t}$ ve vztahu k průměrné hodnotě celkové agregované řady y_t . (Hyndman, 2018, str. 308).

Jednotlivými poměry pak byla vynásobena celková předpověď, čím byly získány předpovědi prodeje pro rok 2016 na úrovni obchodních zástupců. Výsledné předpovědi prodeje na dané úrovni agregace jsou uvedeny v příloze č. 3 této práce.

Model optimálního sladění

Posledním přístupem hierarchického předpovídání poptávky je optimální sladění, jehož výhodou je, že využívá předpovědi na všech úrovních hierarchické struktury. Model bottom up využíval pouze předpovědi prodeje na nejnižší úrovni hierarchické struktury (tj. zákazníků) a model top down naopak na nejvyšší úrovni (tj. celkovou předpověď). Modelem optimálního sladění se nejprve vytvoří součtová matice pro hierarchickou strukturu podle vzorce (38) uvedeného v kapitole 1.2.2.4. této diplomové práce. Tím se získá pro každou úroveň hierarchické struktury vektor optimálních vah, který se nakonec vynásobí nezávislými předpověďmi.

Protože původní datová matice obsahovala 370 sloupců a 378 řádků, a tím pádem výsledná matice s vypočtenými optimálními vahami měla 378 sloupců a 7 řádků, kde každý znamenal jednoho obchodního zástupce, bohužel není uvedena v příloze této diplomové práce. Výsledné časové řady předpovědi prodeje na dané úrovni agregace jsou uvedeny v příloze č. 4 této práce.

2.2.3 Analýza přesnosti předpovědních modelů

Analyzována byla přesnost šesti předpovědních modelů (podnikové předpovědi, model nezávislých předpovědí, hierarchický model bottom-up, hierarchický model top-down a hierarchický model optimálního sladění), přičemž první dva modely v pořadí byly zároveň použity jako referenční modely. Pomocí ukazatele RMSE byla porovnávána přesnost modelů mezi sebou na úrovni zákaznického segmentu obsluhovaného jediným obchodním zástupcem,

zatímco ukazatel MdAPE, který je nezávislý na měřítku dat, sloužil k porovnávání přesnosti předpovědí u jednotlivých obchodních zástupců (tj. podával informaci o tom, u kterých obchodních zástupců lze jednotlivými metodami nejpřesněji odhadnout budoucí prodeje).

Z tabulky 7, která obsahuje hodnoty ukazatele RMSE pro všechny předpovědní modely a zákaznické segmenty, je zřejmé, že nejpřesnějších předpovědí bylo dosaženo pomocí hierarchického modelu bottom-up, který ve většině případů vykazoval nejnižší hodnoty ukazatele RMSE. Model bottom-up tedy poskytuje nejnižší předpovědní chybu u šesti ze sedmi zákaznických segmentů, pouze v segmentu obchodního zástupce OZ4 lze získat přesnější předpovědi pomocí modelu nezávislých předpovědí. Rozdíl mezi hodnotami obou ukazatelů je však v tomto případě zanedbatelný.

Tabulka 7 Hodnoty ukazatele přesnosti RMSE pro jednotlivé metody a zákaznické segmenty

	Podnik	Nezávislé	Bottom up	Top down	Optimální sladění
OZ 1	70,2	52,3	51,7	53,0	58,9
OZ 2	88,3	71,7	56,8	76,3	81,1
OZ 3	352,5	243,4	191,8	218,2	230,7
OZ 4	196,2	135,0	136,0	143,8	138,0
OZ 5	141,9	182,2	116,3	165,7	165,3
OZ 6	160,7	107,7	70,1	96,7	96,2
OZ 7	176,8	101,8	79,3	88,8	89,0

Z tabulky 8, která obsahuje hodnoty ukazatele MdAPE pro všechny metody a zákaznické segmenty, vyplývá, že nejpředvídatelnější (prakticky všemi metodami) je poptávka pro segment obsluhovaný obchodním zástupcem OZ4 a naopak největší relativní chybu vykazují předpovědi poptávky v segmentu obsluhovaného obchodním zástupcem OZ1. To je zřejmě způsobeno i tím, že časová řada prodejů v segmentu OZ1 vykazuje nejvíce nepravidelných (nenáhodných) výkyvů v poptávce (blíže viz kap. 2.2.2.2). Nezávislé předpovědi vykazují největší chybu v segmentu OZ1 a OZ5, přičemž pouze v případě segmentu OZ5 lze tuto chybu významně snížit, a to použitím podnikové předpovědi nebo hierarchické bottom-up metody. Metoda bottom-up je zároveň jedinou hierarchickou metodou, která vykazuje nízkou chybu předpovědí u většiny obchodních zástupců (s výjimkou segmentu OZ1 je hodnota ukazatele MdAPE u této metody menší než 24 %).

Tabulka 8 Hodnoty ukazatele přesnosti MdAPE pro jednotlivé metody a zákaznické segmenty

	Podnik	Nezávislé	Bottom up	Top down	Optimální sladění
OZ 1	47,8%	49,0%	49,3%	46,8%	37,2%
OZ 2	28,3%	15,2%	18,6%	15,5%	18,0%
OZ 3	25,1%	16,2%	9,2%	12,3%	14,3%
OZ 4	7,7%	8,1%	9,8%	10,9%	9,3%
OZ 5	25,5%	48,2%	23,2%	41,7%	41,6%
OZ 6	29,6%	15,5%	14,7%	13,3%	13,7%
OZ 7	38,6%	17,2%	8,5%	13,5%	13,4%

V tabulce 9 jsou uvedeny výsledky analýzy zpřesnění podnikových předpovědí pomocí navržených předpovědních modelů, a to pomocí míry zpřesnění předpovědí (procento snížení RMSE) oproti referenční kvalitativní metodě, kterou daný podnik využívá.

Tabulka 9 Míra zpřesnění podnikových předpovědí použitím navrhovaných metod

	Nezávislé	Bottom up	Top down	Optimální sladění
OZ 1	25,4%	26,3%	24,4%	16,0%
OZ 2	18,8%	35,7%	13,6%	8,1%
OZ 3	30,9%	45,6%	38,1%	34,6%
OZ 4	31,2%	30,7%	26,7%	29,7%
OZ 5	-28,4%	18,1%	-16,8%	-16,5%
OZ 6	33,0%	56,4%	39,8%	40,2%
OZ 7	42,5%	55,1%	49,8%	49,7%
Průměr	21,9%	38,3%	25,1%	23,1%

Z výsledků této analýzy vyplývá, že se pomocí navržených modelů podařilo zvýšit přesnost podnikových předpovědí ve všech případech. Největšího snížení chyby předpovědi bylo dosaženo hierarchickou metodou bottom-up (snížení chyby podnikových předpovědí v průměru o 38,3 %). Zdánlivou výjimku představuje segment OZ4, u kterého bylo docíleno nepatrně lepších výsledků pomocí nezávislých předpovědí, zjištěný rozdíl 0,5 % však představuje zanedbatelnou hodnotu. Hierarchický model bottom-up je zároveň jediným hierarchickým modelem, který dokáže zpřesnit podnikové předpovědi na úrovni všech zákaznických segmentů. Nejnižšího snížení chyby podnikových předpovědí v průměru

o 21,9 % bylo naopak docíleno pomocí nezávislých předpovědí. Nicméně volbou vhodného předpovědního lze zpřesnit podnikové předpovědi od 18,1 % do 56,4 %.

Významnost hierarchického modelu bottom-up je ještě patrnější v případě, pokud jako referenční metodu zvolíme nezávislé předpovědi. Procenta zpřesnění nezávislých předpovědí pomocí hierarchických modelů, která jsou uvedena v Tabulce 10, totiž přímo kvantifikují příspěvek ke snížení předpovědní chyby RMSE díky použití hierarchických přístupů k předpovídání poptávky.

Tabulka 10 Míra zpřesnění statistických předpovědí použitím hierarchických metod

	Bottom up	Top down	Optimální sladění
OZ 1	1,3%	-1,3%	-12,6%
OZ 2	20,7%	-6,5%	-13,2%
OZ 3	21,2%	10,3%	5,2%
OZ 4	-0,8%	-6,6%	-2,2%
OZ 5	36,2%	9,0%	9,3%
OZ 6	34,9%	10,2%	10,7%
OZ 7	22,1%	12,7%	12,5%
Průměr	19,4%	4,0%	1,4%

Z této analýzy vyplývá, že použitím hierarchických přístupů k předpovídání poptávky lze zpřesnit statistické předpovědi. Největšího zpřesnění lze pak dosáhnout pomocí modelu bottom-up, který vykazuje průměrné snížení chyby statistických předpovědí o 19,4 %. Jedná se o model, při kterém jsou statistické předpovědi tvořeny na nejnižší úrovni hierarchie (tj. pro jednotlivé zákazníky), které jsou následně sumarizovány do zákaznických segmentů (požadovaná struktura podnikových předpovědí).

Naopak nejhůře vychází z analýzy model optimálního sladění, u kterého došlo k průměrnému zpřesnění statistických předpovědí pouze o 1,4 %. V tomto případě se jedná zároveň o nejpracnější hierarchický model (analýza časových řad na všech úrovních hierarchie poptávky), jehož použití v podniku by s sebou přinášelo další problémy při stanovení matice vah. Kdyby nedocházelo ke změnám v hierarchické struktuře poptávky, matice vah by v podniku mohla být stanovena pouze jednou, protože je závislá pouze na hierarchické struktuře, nikoliv na vstupních datech. Ovšem po provedení analýzy vstupních dat bylo zjištěno, že hierarchická struktura poptávky daného podniku (počet zákazníků

podniku) se nepatrně měnila každý rok, proto by se každý rok musela tvořit nová matice vah a daný model se tak stává nejpracnějším ze všech použitých modelů.

Model bottom-up je sice oproti současnému způsobu předpovídání v podniku také pracnějším (nutnost analýzy 1777 časových řad oproti současným 7), jeho použití však může být pro podnik výhodné. V případě, kdyby podnik zvolil hierarchický model bottom-up, snížil by chybu podnikových předpovědí v průměru o 38,3 %. V případě zachování stejné pracnosti předpovídání (analýza časových řad pouze na požadované úrovni agregace poptávky) bych podniku doporučila použití statistických metod, které v analyzovaném případě snížily chybu podnikových předpovědí v průměru o 21,9 %.

ZÁVĚR

Předpovídání poptávky je pro podniky velmi zásadní a měli by mu věnovat dostatečný čas, protože přesné informace jim pomáhají reagovat na změny v poptávce zákazníků, zvyšovat dostupnost produktů na trhu, zvyšovat úroveň zákaznických služeb, ale i zefektivnit marketingovou komunikaci, a tak získat významnou konkurenční výhodu na trhu.

Samotné předpovídání poptávky lze v podniku realizovat v pěti základních krocích. Prvním krokem je definování předpovědního problému, tj. vymezení toho, pro jaké rozhodování se bude předpověď tvořit, kdo ji bude tvořit a jakým způsobem. Následuje sběr informací a předběžná analýza dat pomocí grafů, ze kterých lze zjistit, zda data obsahují trend, sezónní kolísání nebo nějaké odlehle hodnoty. Tento krok pomůže analytikovi při výběru vhodné metody pro předpovídání. Dalším krokem je tedy výběr vhodné metody a posledním krokem je samotná tvorba předpovědi a ohodnocení přesnosti předpovědi.

Metody předpovídání lze rozdělit do dvou skupin, a to na metody kvalitativní a kvantitativní. Kvalitativní metody jsou založeny na úsudku, zkušenostech a názorech jednotlivců nebo skupin, kteří předpovědi tvoří. Patří mezi ně Delfská metoda, metoda historické analogie, názory prodejců, brainstorming a další. Jejich hlavní výhodou je, že na rozdíl od kvantitativních metod nevyžadují tak velké množství historických dat. Za největší nevýhodu lze považovat vysoký podíl subjektivity na tvorbě předpovědi. Kvantitativní metody, které se opírají o analýzu časových řad, sice vykazují vyšší stupeň objektivity, to však neznamená, že jsou ve všech případech předpovídání poptávky vhodnější. Jejich nevýhodou je zejména to, že předpokládají, že se v budoucnu nebude měnit charakter vývoje poptávky. Mezi tyto metody patří například exponenciální vyrovnávání, Box – Jenkinsonova metodologie a lineární regrese.

Protože předpovídání poptávky v podnicích často vyžaduje tvorbu předpovědi na různých stupních agregace poptávky, využívají podniky tzv. hierarchické předpovídání pro tvorbu systému vzájemně sladěných předpovědí. Takový systém předpovědi lze vytvářet buď pomocí hierarchických metod bottom-up, top-down, middle-out nebo metodou optimálního sladění. Hierarchické předpovídání je velmi složitý proces, u kterého volba vhodné metody závisí na charakteru předpovídané poptávky a dostupných datech. Výhodou metody bottom-up je, že vychází z předpovědi na nejnižším stupni hierarchie, a nedochází tak ke ztrátě informací v důsledku agregace poptávky. Na druhou stranu předpovídání na nejnižší úrovni hierarchické struktury vyžaduje tvorbu velkého počtu předpovědí a často je spojené

s problémem předpovídání řídké poptávky. Tyto nevýhody odstraňuje metoda top-down, která vychází z jediné předpovědi na nejvyšší úrovni hierarchické struktury poptávky. To je však naopak spojeno s problematickou volbou vhodného způsobu, jakým bude celková předpověď desagregována na nižší stupně hierarchie poptávky. Metoda optimálního sladění využívá nezávislých předpovědí na všech úrovních hierarchie poptávky, které jsou pomocí lineární regrese sladěny do požadované struktury konečných předpovědí. Jedná se sice o nejpracnější metodu, ale v případech, kdy podnik vyžaduje znalost předpovědí na různých stupních agregace poptávky, obvykle poskytuje nejlepší výsledky.

Většina výzkumů v oblasti hierarchického předpovídání řeší možnosti sladování předpovědí na různých stupních agregace poptávky tak, aby byla celková chyba podnikových předpovědí minimalizována. Literatura však nedostatečně řeší možnosti použití hierarchických modelů při zpřesňování předpovědi na jediném (požadovaném) stupni agregace, tedy možnosti zpřesnění předpovědi poptávky pomocí analýzy časových řad na jiném stupni agregace, než je předpovídaný problém. Z toho důvodu bylo cílem výzkumu ve vybraném potravinářském podniku identifikovat možnosti použití hierarchických přístupů k předpovídání poptávky při snižování chyby podnikových předpovědí.

Na základě polostrukturovaného rozhovoru s obchodním ředitelem ze zkoumaného podniku byl v práci identifikován předpovědní problém a požadovaná struktura podnikových předpovědí (měsíční předpovědi prodeje v sedmi zákaznických segmentech). Pomocí dostupných informací o poptávce a analýzy podnikových dat byly následně navrženy tři hierarchické předpovědní modely (model bottom-up, model top-down a model optimálního sladění), které byly použity při tvorbě podnikových předpovědí na požadovaném stupni agregace poptávky. Takto získané předpovědi byly porovnány nejen s podnikovými předpověďmi (kvalitativní předpověď), ale také se statistickými předpověďmi, které jsou tvořeny pouze na jediném stupni agregace poptávky. To umožnilo kvantifikovat nejen možnosti zpřesnění podnikových předpovědí, ale také přínos hierarchických přístupů k předpovídání poptávky ve srovnání s běžnými statistickými metodami.

Na základě analýzy přesnosti předpovědí bylo zjištěno, že aplikací kteréhokoli z navrhovaných hierarchických modelů lze zvýšit přesnost podnikových předpovědí. Největšího zpřesnění bylo dosaženo modelem bottom-up (snížení chyby podnikových předpovědí o 38 %), při kterém jsou tvořeny předpovědi na nejnižším stupni zákaznické

agregace, které jsou následně sumarizovány do požadované struktury podnikových předpovědí.

Výsledky výzkumu také ukázaly, že hierarchické přístupy k předpovídání umožňují významným způsobem zvýšit přesnost statistických předpovědí, které jsou tvořeny pouze na jediném (požadovaném) stupni hierarchie poptávky. Zatímco u modelu top-down a modelu optimálního sladění byla snížena chyba předpovědí pouze nepatrně (4,0 %, resp. 1,4 %), pomocí modelu bottom-up se podařilo snížit chybu o 19,4 %.

POUŽITÁ LITERATURA

1. Abu Bakar, S.A., Hamzah N.A., Maghsoudi M, Nadarajah S(2015). *Modeling loss data using composite models. Insurance: Mathematics and Economics* [online]. 61, 146-154 [cit. 2019-01-06]. DOI: 10.1016/j.insmatheco.2014.08.008. ISSN 01676687.
2. Arlt, J. (1999). *Moderní metody modelování ekonomických časových řad*. Praha: Grada ISBN 80-7169-539-4.
3. Arlt, J., Arltová, M. (2007). *Ekonomické časové řady: [vlastnosti, metody modelování, příklady a aplikace]*. Praha: Grada. Studijní texty (Sociologické nakladatelství). ISBN 978-80-247-1319-9.
4. Arltová, M. a Arlt J.(1995) , *Grafické metody analýzy ekonomických časových řad*. Statistika [online], str. 483 - 493. ISSN N 0322-788x. Dostupné z: https://nb.vse.cz/~arlt/hlavni/publik/AA_GMAECCR_95.pdf
5. Brockwell, P. (2016) *Introduction to time series and forecasting*. New York. NY: Springer Science Business Media. ISBN 978-3-319-29852-8.
6. Cipra, T. (2013). *Finanční ekonometrie. 2., upr. vyd.* Praha: Ekopress. ISBN 978-80-86929-93-4.
7. Fliedner, G. (1999). *An investigation of aggregate variable time series forecast strategies with specific subaggregate time series statistical correlation*. 26(10-11).
8. Fliedner, G. (2001). *Hierarchical forecasting: issues and use guidelines*. 101(1).
9. Gros, I. (2009). *Matematické modely pro manažerské rozhodování*. 1.st ed. Praha - VŠCHT Praha. / . 001. ISBN 978-80-7080-5.
10. Gros, I., Dyntar J., Grosová S. 2006. *Předpovědi sporadické poptávky*. Logistika, roč. 12, č. 4. ISSSN 1211-0957.
11. Grossová, S. (2002). *Marketing: principy, postupy, metody*. Praha: Vysoká škola chemicko-technologická. ISBN 80-708-0505-6.
12. Formánek, T. (2004). *Demand planning v praxi*. System On Line.
13. Hindls R. (2007). *Statistika pro ekonomy*. 8. vyd. Praha: Professional Publishing. ISBN 978-80-86946-43-6.
14. Horáková, H., & Kubát, J. (1999). *Řízení zásob: logistické pojetí, metody, aplikace, praktické úlohy*. (3., přeprac. vyd). Praha: Profess Consulting.
15. Hyndman, R. (2008). *Forecasting with exponential smoothing: the state space approach*. Springer, Berlín.
16. Hyndman, R., Ahmed R. A., Athanasopoulos G. (2011). *Optimal combination forecasts for hierarchical time series*. 55 (9), 2579-2589. DOI: 10.1016/j.csda.2011.03.006. ISSN 01679473.




17. Hyndman, R., Athanasopoulos, G. (2014). *Optimally Reconciling Forecasts in a Hierarchy*. International Institute of Forecasters. *Fall*, 35.
18. Hyndman, R., Athanasopoulos, G. (2018). *Forecasting: principles and practice*. 2. OTexts. ISBN 978-0-9875071-1-2.
19. Hušek, R. (2007). *Ekonomická analýza*. Praha: Oeconomica. ISBN 978-80-245-1300-3.
20. Kavan, M. (2002). *Výrobní a provozní management*. (1. vyd). Praha: Grada.
21. Kim, D., Song, J., Kim D. (2007). *Simultaneous gesture segmentation and recognition based on forward spotting accumulative HMMs*. *Pattern Recognition*. 40(11), 3012-3026 DOI: 10.1016/j.patcog.2007.02.010. ISSN 00313203.
22. Kotler, P., & Keller, K. (2007). *Marketing management*. (1. vyd). Praha: Grada.
23. Kotler, P. (2007). *Moderní marketing*. (1. vyd). Praha: Grada.
24. Lošťáková, H. (2009). *Diferencované řízení vztahů se zákazníky: [moderní strategie růstu výkonnosti podniku]*. (1. vyd). Praha: Grada.
25. Lošťáková, H. (2013). *Marketingový management*. Pardubice: Univerzita Pardubice.
26. Xu, Lu, Hai-Yan Fu, Mohammad Goodarzi, Chen-Bo Cai, Qiao-Bo Yn, Ya Wu, Bang-Cheng Tang a Yuan-Bin She. (2018) *Stochastic cross validation*. *Chemometrics and Intelligent Laboratory Systems*. 175, 74-81 DOI: 10.1016/j.chemolab.2018.02.008. ISSN 01697439.
27. Mirčetić, D., Nikoličić, S., Stojanović, Đ., Maslarić, M. (n. d.). (2017) *Modified top down approach for hierarchical forecasting in a beverage supply chain*. *Transportation Research Procedia*, (22), 193-202. DOI: 10.1016/j.trpro.2017.03.026. ISSN 23521465.
28. Mentzer, J.T., Moon M.A. (2005) *Sales forecasting management: a demand management approach*. 2nd ed. Thousand Oaks: Sage Publications, c2005. ISBN 978-1-4129-0571-8.
29. Ömer Faruk D. (2010). *A hybrid neural network and ARIMA model for water quality time series prediction*. *Engineering Applications of Artificial Intelligence* [online]. **23**(4), 586-594 [cit. 2019-01-06]. DOI: 10.1016/j.engappai.2009.09.015. ISSN 09521976.
30. Paták, M., Vlčková, V. (2010). *Time series forecasting as a tool of operative management*. *Scientific papers of the university of Pardubice*, (16).
31. Paták, M., Vlčková V. (2013). *Sales structure and its impact on accuracy of short-term sales forecasting in manufacturing companies*. *Scientific Papers of the University of Pardubice: Series A, Faculty of Chemical Technology*. (19), 335-344.

32. Pennings, C., & van Dalen, J. (2017). *Integrated hierarchical forecasting*. European Journal of Operational Research, 263(2).
33. Preclík, V. (2006). *Průmyslová logistika*. Praha: Nakladatelství ČVUT. ISBN 80-010-3449-6
34. Pojkarová K. (2014). *Ekonometrie a prognostika v dopravě: studijní opora*. Vyd. 2., dopl. a opr. Pardubice: Univerzita Pardubice. ISBN 978-80-7395-838-1.
35. Potůček, M., ed. (2006). *Manuál prognostických metod*. Praha: Sociologické nakladatelství. Studijní texty (Sociologické nakladatelství). ISBN 80-864-2955-5.
36. Ramos, P., Santos N, Rebelo R.(2015). *Performance of state space and ARIMA models for consumer retail sales forecasting*. Robotics and Computer-Integrated Manufacturing [online]. **34**, 151-163 [cit. 2019-01-06]. DOI: 10.1016/j.rcim.2014.12.015. ISSN 07365845.
37. Rostami-Tabar, B., Babai, M., Ducq, Y., & Syntetos, A. (2015). *Non-stationary demand forecasting by cross-sectional aggregation*. International Journal of Production Economics, vol. 170.
38. Sedláková, R. (2014). *Výzkum médií: nejužívanější metody a techniky*. Praha: Grada. Žurnalistika a komunikace. ISBN 978-80-247-3568-9.
39. Soukup, P. (2010). *Nesprávná užívání statistické významnosti a jejich možná řešení*. Institut sociologických studií. Fakulta sociálních věd, Univerzita Karlova v Praze. Vol. 4, No. 2: 77 - 104. Sociologický ústav AV ČR, Praha.
40. Stander, H., Kilger, Ch. (2005). *Supply chain management and advanced planning: concepts, models, software and case studies*. 3rd ed. New York: Springer. ISBN 35-402-2065-8.
41. Stuchlý, J. (2001). *Statistické metody pro manažerské rozhodování*. (Vyd. 1). Praha: Vysoká škola ekonomická.
42. Syntetos, A., Babai, Z., Boylan, J., Kolassa, S., & Nikolopoulos, K. (2016). *Supply chain forecasting: Theory, practice, their gap and the future*. European Journal of Operational Research, 252(1).
43. Štědroň, B. (2012). *Prognostické metody a jejich aplikace*. (Vyd. 1). V Praze: C.H. Beck.
44. Vlčková V., Machač O., Paták M. (2013). *Aplikovaná statistika: studijní opora na CD*. Pardubice: Univerzita Pardubice. ISBN 978-80-7395-668-4.


45. Zotteri, G., & Kalchschmidt, M. (2007). *A model for selecting the appropriate level of aggregation in forecasting processes*. *International Journal of Production Economics*, 108(1-2).

PŘÍLOHY


Příloha 1 Grafy časových řad prodejů v období 2013-2016 (modrá křivka) a nezávislých předpovědí v testovaném období časové řady (oranžová křivka)




Obchodní zástupce 3




Obchodní zástupce 4




Obchodní zástupce 5



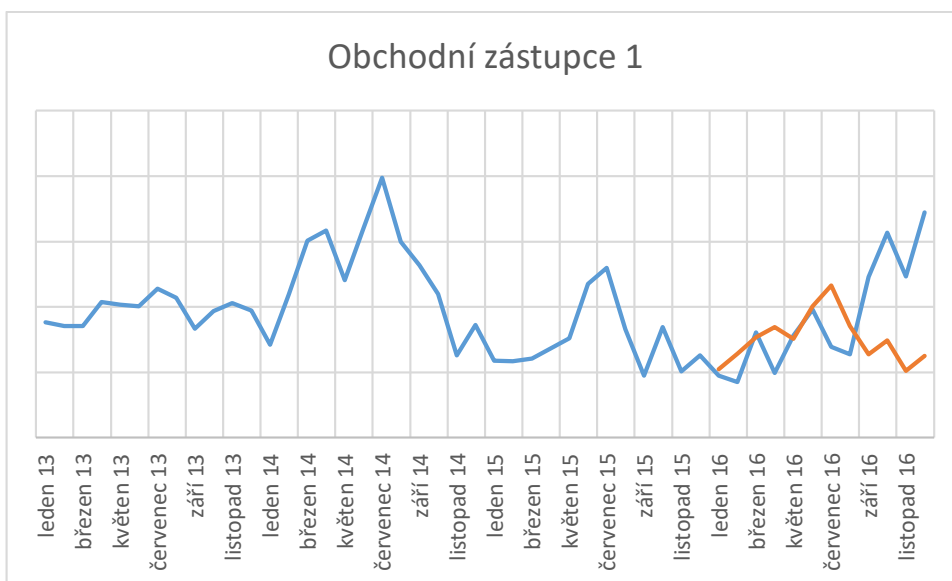

Obchodní zástupce 6




Obchodní zástupce 7




Příloha 2 Grafy časových řad prodejů v období 2013-2016 (modrá křivka) a předpovědí tvořené modelem bottom up v testovaném období časové řady (oranžová křivka)




Obchodní zástupce 2




Obchodní zástupce 3




Obchodní zástupce 4




Obchodní zástupce 5





Obchodní zástupce 6




Obchodní zástupce 7




Příloha 3 Grafy časových řad prodejů v období 2013-2016 (modrá křivka) a předpovědí tvořené modelem top down v testovaném období časové řady (oranžová křivka)




Obchodní zástupce 2




Obchodní zástupce 3




Obchodní zástupce 4




Obchodní zástupce 5





Obchodní zástupce 6




Obchodní zástupce 7




Příloha 4 Grafy časových řad prodejů v období 2013-2016 (modrá křivka) a předpovědí tvořené modelem optimálního sladění v testovaném období časové řady (oranžová křivka)




Obchodní zástupce 2




Obchodní zástupce 3




Obchodní zástupce 4



Obchodní zástupce 5



Obchodní zástupce 6



Obchodní zástupce 7

