

Disertační práce

**Algoritmy řízení ve výrobě a rozvodu tepla:
Předpověď denního diagramu dodávky tepla**

Ing. Bronislav Chramcov

Školitel: Prof. Ing. Jaroslav Balátě, DrSc.

Universita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky
Ústav aplikované informatiky

Zlín, 2006

Poděkování:

Je pro mne milou povinností poděkovat svému školiteli Prof. Ing. Jaroslavu Balátě, DrSc. za odborné vedení během celého studia v rámci doktorského studijního programu. Dále bych chtěl poděkovat Doc. Ing. Petru Dostálovi, CSc. za konzultace, cenné rady a připomínky při zpracování disertační práce.

Poděkování patří také všem mým blízkým, kteří se mnou měli dostatek trpělivosti v době, kdy jsem dokončoval tuto práci.

RESUMÉ

Předkládaná disertační práce se zabývá využitím predikce časové řady při řízení technologického procesu. Konkrétně se jedná o technologický proces dodávky tepla v soustavě centralizovaného zásobování teplem (SCZT), speciálně pro řízení tepelného výkonu horkovodu, kde se vyskytuje při řízení běžně používaným kvalitativním způsobem dopravní zpoždění a to v rozsahu 2 – 12 hodin v závislosti na lokalitě (tj. na délce potrubního řádu). Podstatou práce je pak rozpracování metodologie Box-Jenkinse takovým způsobem, aby byla použitelná pro výpočet předpovědi průběhu časové řady denního diagramu dodávky tepla (DDDT) v soustavě centralizovaného zásobování teplem.

V práci je nejdříve řešena problematika výstavby modelu časové řady DDDT. Tato část mimo jiné odpovídá na otázku co je třeba všechno udělat s časovou řadou před vlastní predikcí. Jsou zde objasněny pojmy jako vyrovnaní časové řady, transformace časové řady, určení řádu diferencování a další. Tyto jednotlivé fáze výstavby modelu jsou pak prakticky ilustrovány na konkrétní časové řadě DDDT.

Hlavním přínos spočívá v návrhu metodologie pro zahrnutí nepravidelných kalendářních vlivů a zahrnutí vlivu meteorologických veličin do výpočtu předpovědi DDDT. Jde o řešení situace, kdy státem uznávaný svátek resp. den pracovního klidu připadne na pracovní den a situace náhlých výkyvů počasí. Nejvýznamnějším meteorologickým faktorem ovlivňující průběh DDDT je venkovní teplota vzduchu, proto se práce zaměřuje na zahrnutí tohoto vlivu do výpočtu předpovědi DDDT.

Přímým výstupem je pak komplexní výpočetní program v prostředí MATLAB, který může sloužit především pro provozovatele popřípadě projektanty tepelných sítí.

Je nutné zdůraznit, že všechny experimenty jsou prováděny na reálných datech, které byly získány díky úzké spolupráci výzkumného pracoviště s provozem v energetických podnicích. V našem případě se jedná o úzkou spolupráci s MST a.s. –Teplárnou Olomouc, respektive s Teplárnou Otrokovice, a.s. Dosažené výsledky pak naznačují praktickou použitelnost tohoto přístupu.

SUMMARY

This thesis is aimed at utilization of time series prediction for control of technological process. We can find an application of this prediction also by the control in the Centralised Heat Supply System (CHSS), especially for control of hot-water piping heat output, where transport delay namely in the range 2 up to 12 hours depending on each locality (length of piping) occurs in common use qualitative way of control. Development of Box-Jenkins methodology for prediction of Heat Supply Daily Diagram (HSDD) course in CHSS is the subject of this work.

Firstly the problem of building the model of time series of HSDD is solve. This part take question what is necessary to do with time series before prediction. Terms as a smoothing of time series, transformation of time series, order of model and other are clear up there. These individual phases of model building are demonstrate on specific time series of HSDD.

The main contribution consist in design of methodology for inclusion of irregular calendar influences and inclusion of meteorological influences for prediction of HSDD. It is situation, when holiday fall on working day and situation of sudden fluctuation of meteorological influences. Outdoor temperature is the most significant meteorological factor that affect the course of HSDD. From this point of view this work focus on inclusion of this influence for calculation of HSDD prediction.

Complex program in MATLAB is the direct output of this work. It can be of service especially to operator eventually designer of heat networks.

It is necessary to stress that the real data are used for all experiments. The real data were obtained due to close cooperation of our research workplace with energy plant operations. In our case it is close cooperation with company MST a.s. – Power and Heating plant Olomouc or Power and Heating Plant Otrokovice, a.s. Experiments and the results indicate practicability of the method.

OBSAH

SEZNAM OBRÁZKŮ	9
SEZNAM TABULEK.....	14
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	15
1 ÚVOD.....	19
1.1 STRUKTURA DISERTAČNÍ PRÁCE	21
2 SOUČASNÝ STAV PROBLEMATIKY – LITERÁRNÍ REŠERŠE	22
2.1 METODY PŘEDPOVĚDI ČASOVÝCH ŘAD.....	22
2.2 PŘEDPOVĚĎ ČASOVÝCH ŘAD S APLIKACEMI V ENERGETICE.....	25
2.3 PŘEDPOVĚĎ DODÁVKY TEPLA V SOUSTAVÁCH CENTRALIZOVANÉHO ZÁSOBOVÁNÍ TEPLEM	28
3 CÍLE DISERTAČNÍ PRÁCE	31
4 TEORETICKÝ RÁMEC.....	32
4.1 ZÁKLADNÍ POJMY A APARÁT BOXOVY-JENKINSOVY METODOLOGIE	32
4.1.1 <i>Stochastický proces a stacionarita.....</i>	33
4.1.2 <i>Autokovarianční a autokorelační fce.</i>	33
4.1.3 <i>Parciální autokorelační funkce.....</i>	35
4.1.4 <i>Proces bílého šumu.....</i>	36
4.1.5 <i>Jednoduché operátory.....</i>	37
4.1.6 <i>Lineární proces.....</i>	37
4.1.7 <i>Proces klouzavých součtů.....</i>	39
4.1.8 <i>Autoregresní proces.....</i>	39
4.1.9 <i>Smíšený proces.....</i>	40
4.1.10 <i>Nestacionární proces.....</i>	40
4.2 MODEL PODLE BOX-JENKINSE.....	41
4.2.1 <i>Obecný postup výpočtu predikce podle Box-Jenkinse.....</i>	44
5 METODY A ZPŮSOB VÝPOČTU PREDIKCE ČASOVÉ ŘADY DDDT	51
5.1 REÁLNÁ ČASOVÁ ŘADA DDDT	51
5.2 VÝSTAVBA MODELU PRO ČASOVOU ŘADU DDDT	54
5.2.1 <i>Vyrovnání(vyhlazení) časové řady.....</i>	55
5.2.2 <i>Transformace časové řady.....</i>	58
5.2.3 <i>Určení řádu diferencování.....</i>	60
5.2.4 <i>Určení řádu autoregresního polynomu a řádu polynomu klouzavých součtů....</i>	68

5.2.5	<i>Diagnostická kontrola modelu</i>	69
5.2.6	<i>Kriteria pro volbu modelu</i>	71
5.3	METODY VÝPOČTU PŘEDPOVĚDI DDDT	77
5.3.1	<i>Metoda využívající model s dvojnásobnou filtrací</i>	77
5.3.2	<i>Metoda superpozice modelů</i>	78
5.4	ZPŮSOB VÝPOČTU PREDIKCE DDDT	81
5.5	ZAHRNUTÍ NEPRAVIDELNÝCH KALENDÁRNÍCH VLVIVŮ.....	82
5.6	ZAHRNUTÍ Vlivu VENKOVNÍ TEPLoty NA PRŮBĚH DDDT	86
6	EXPERIMENTÁLNÍ ČÁST	93
6.1	PROGRAM V PROSTŘEDÍ MATLAB.....	93
6.2	KONKRÉTNÍ VÝSLEDKY PREDIKCE	99
6.2.1	<i>Konkrétní výsledky predikce DDDT metodou dvojí filtrace</i>	99
6.2.2	<i>Konkrétní výsledky predikce DDDT metodou superpozice modelů</i>	103
6.2.3	<i>Konkrétní výsledky predikce DDDT se zahrnutím nepravidelných kalendářních vlivů</i>	107
6.2.4	<i>Konkrétní výsledky predikce DDDT se zahrnutím vlivu venkovní teploty</i>	110
7	VYUŽITELNOST VÝSLEDKŮ ŘEŠENÍ	119
7.1	KVALITATIVNĚ – KVANTITATIVNÍ ZPŮSOB ŘÍZENÍ TEPELNÉHO VÝKONU HORKOVODU	120
7.1.1	<i>Kvalitativně-quantitativní způsob řízení tepelného výkonu horkovodu s využitím predikce průběhu denního diagramu dodávky tepla v systémech centralizovaného zásobování teplem</i>	121
7.1.2	<i>Algoritmus kvalitativně-quantitativního způsobu řízení výkonu horkovodu s horkovodními kotli jako zdroji tepla</i>	125
7.2	OPTIMÁLNÍ ROZDĚLOVÁNÍ ZATÍŽENÍ.....	130
7.2.1	<i>Metoda funkce poměrných přírůstků</i>	130
7.2.2	<i>Návrh kriteria režimového optima</i>	132
8	ZÁVĚR	138
9	PUBLIKAČNÍ AKTIVITY	139
10	LITERATURA	147
	PŘÍLOHY	156

SEZNAM OBRÁZKŮ

<i>Obr. 5.1: Časová řada DDDT z lokality Olomoucka</i>	51
<i>Obr. 5.2: Časová řada DDDT z lokality Olomoucka – DETAIL</i>	52
<i>Obr. 5.3: Časová řada DDDT z lokality Zlínka</i>	52
<i>Obr. 5.4: Časová řada DDDT z lokality Zlínka - DETAIL</i>	53
<i>Obr. 5.5: Část časové řady DDDT určená k vyhlazení pomocí klouzavých průměrů</i>	57
<i>Obr. 5.6: Průběhy klouzavých průměrů 3. řádu pro délky 5 a 9</i>	58
<i>Obr. 5.7: Časová řada DDDT – lokalita Olomoucka (bez sobot a nedělí)</i>	61
<i>Obr. 5.8: Časová řada DDDT – lokalita Zlínka (bez sobot, nedělí a svátku 28.10.)</i>	62
<i>Obr. 5.9: Řada prvních diferencí časové řady DDDT – lokalita Olomoucka</i>	62
<i>Obr. 5.10: Řada prvních diferencí časové řady DDDT – lokalita Zlínka</i>	63
<i>Obr. 5.11: Odhadnutá autokorelační funkce pro původní nediferencovanou časovou řadu DDDT – lokalita Olomoucka</i>	64
<i>Obr. 5.12: Odhadnutá autokorelační funkce pro původní nediferencovanou časovou řadu DDDT – lokalita Zlínka</i>	65
<i>Obr. 5.13: Odhadnutá autokorelační funkce pro diferencovanou časovou řadu DDDT – lokalita Olomoucka</i>	65
<i>Obr. 5.14: Odhadnutá autokorelační funkce pro diferencovanou časovou řadu DDDT – lokalita Zlínka</i>	66
<i>Obr. 5.15: Řada po sezónním i běžném diferencování – lokalita Olomoucka</i>	67
<i>Obr. 5.16: Řada po sezónním i běžném diferencování – lokalita Zlínka</i>	67
<i>Obr. 5.17: Hodnoty Akaikeho kriteria (AIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Olomoucka</i>	73
<i>Obr. 5.18: Hodnoty Schwartzova kriteria (SC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Olomoucka</i>	73
<i>Obr. 5.19: Hodnoty Bayesovského kriteria (BIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Olomoucka</i>	74
<i>Obr. 5.20: Hodnoty Akaikeho kriteria (AIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Zlínka</i>	74
<i>Obr. 5.21: Hodnoty Schwartzova kriteria (SC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Zlínka</i>	75
<i>Obr. 5.22: Hodnoty Bayesovského kriteria (BIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Zlínka</i>	75

<i>Obr. 5.23: Průběh předpovědi časové řady DDDT – lokalita Zlínka pro volbu $p=1$, $q=0$.....</i>	<i>76</i>
<i>Obr. 5.24: Průběh předpovědi časové řady DDDT – lokalita Zlínka pro volbu $p=3$, $q=0$.....</i>	<i>77</i>
<i>Obr. 5.25: Postup výpočtu predikce metodou superpozice modelů.....</i>	<i>79</i>
<i>Obr. 5.26: Závislost mezi indexy časů t^* a t^{**}.....</i>	<i>81</i>
<i>Obr. 5.27: Ukázka grafického znázornění predikce s pásmem pravděpodobnosti 50% a 95%.....</i>	<i>82</i>
<i>Obr. 5.28: Metoda posouvajícího se horizontu</i>	<i>82</i>
<i>Obr. 5.29: Ukázka průběhu korekční topné charakteristiky – kubická fce.....</i>	<i>87</i>
<i>Obr. 5.30: Ukázka průběhu korekční topné charakteristiky – po částech lineární funkce</i>	<i>88</i>
<i>Obr. 5.31: Reálný průběh časové řady DDDT</i>	<i>89</i>
<i>Obr. 5.32: Reálný průběh filtrované časové řady DDDT.....</i>	<i>90</i>
<i>Obr. 5.33: Srovnání průběhu predikované časové řady DDDT se skutečnými odběry před zpětnou filtrací.....</i>	<i>91</i>
<i>Obr. 5.34: Srovnání průběhu predikované časové řady DDDT se skutečnými odběry po provedení zpětné filtrace.....</i>	<i>91</i>
<i>Obr. 6.1: Částečný výpis textových souborů s daty z lokality Zlínka a Olomoucka.....</i>	<i>93</i>
<i>Obr. 6.2: Vstupní okno výpočetního programu</i>	<i>94</i>
<i>Obr. 6.3: Okno nastavení řádu modelu</i>	<i>94</i>
<i>Obr. 6.4: Okno pro nastavení výpočtu se zahrnutím kalendářních vlivů</i>	<i>95</i>
<i>Obr. 6.5: Okno nastavení po částech se měnící funkce</i>	<i>96</i>
<i>Obr. 6.6: Okno nastavení kubické funkce.....</i>	<i>97</i>
<i>Obr. 6.7: Výstupní grafické okno.....</i>	<i>97</i>
<i>Obr. 6.8: Okno s výsledky experimentu.....</i>	<i>98</i>
<i>Obr. 6.9: Grafické zobrazení průběhu predikce metodou dvojití filtrace pro vzorkovací periodu 1 hodina (lokalita Olomoucka).....</i>	<i>100</i>
<i>Obr. 6.10: Grafické zobrazení průběhu predikce metodou dvojití filtrace pro vzorkovací periodu 30 minut (lokalita Olomoucka).....</i>	<i>100</i>
<i>Obr. 6.11: Grafické zobrazení průběhu predikce metodou dvojití filtrace pro vzorkovací periodu 30 minut s použitím vyhlazení časové řady (lokalita Olomoucka).....</i>	<i>101</i>
<i>Obr. 6.12: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody dvojití filtrace (lokalita Olomoucka)</i>	<i>101</i>

<i>Obr. 6.13: Grafické zobrazení průběhu predikce metodou dvojí filtrace pro vzorkovací periodu 1 hodina (lokalita Zlínska)</i>	<i>102</i>
<i>Obr. 6.14: Grafické zobrazení průběhu predikce metodou dvojí filtrace pro vzorkovací periodu 1 hodina s použitím vyhlazení časové řady (lokalita Zlínska)</i>	<i>102</i>
<i>Obr. 6.15: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody dvojí filtrace (lokalita Zlínska)</i>	<i>103</i>
<i>Obr. 6.16: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 1 hodina (lokalita Olomoucka).....</i>	<i>104</i>
<i>Obr. 6.17: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 30 minut (lokalita Olomoucka).....</i>	<i>104</i>
<i>Obr. 6.18: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 30 minut s použitím vyhlazení časové řady (lokalita Olomoucka).....</i>	<i>105</i>
<i>Obr. 6.19: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody superpozice modelů (lokalita Olomoucka)</i>	<i>105</i>
<i>Obr. 6.20: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 1 hodina (lokalita Zlínska)</i>	<i>106</i>
<i>Obr. 6.21: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 1 hodina s použitím vyhlazení časové řady (lokalita Zlínska)</i>	<i>106</i>
<i>Obr. 6.22: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody superpozice modelů (lokalita Zlínska).....</i>	<i>107</i>
<i>Obr. 6.23: Grafické zobrazení průběhu predikce DDDT na den 28.10.1996 bez zahrnutí nepravidelných kalendářních vlivů (lokalita Zlínska)</i>	<i>107</i>
<i>Obr. 6.24: Grafické zobrazení průběhu predikce DDDT na den 28.10.1996 se zahrnutím nepravidelných kalendářních vlivů (lokalita Zlínska)</i>	<i>108</i>
<i>Obr. 6.25: Výsledky ve formě konkrétních hodnot pro předpovědi na den 28.10.1996 bez zahrnutí resp. se zahrnutím nepravidelných kalendářních vlivů</i>	<i>108</i>
<i>Obr. 6.26: Grafické zobrazení průběhu predikce DDDT na následující pondělí tj.4.11.1996 bez zahrnutí nepravidelných kalendářních vlivů</i>	<i>109</i>
<i>Obr. 6.27: Grafické zobrazení průběhu predikce DDDT na následující pondělí tj.4.11.1996 se zahrnutím nepravidelných kalendářních vlivů.....</i>	<i>109</i>
<i>Obr. 6.28: Výsledky ve formě konkrétních hodnot pro předpovědi na následující pondělí tj. den 4.11.1996 bez zahrnutí resp. se zahrnutím nepravidelných kalendářních vlivů.....</i>	<i>110</i>
<i>Obr. 6.29: Grafické zobrazení průběhu venkovní teploty v období 20.11.-24.11.1998 (lokalita Olomoucka, vzorkovací perioda 30 minut).....</i>	<i>111</i>

<i>Obr. 6.30: Grafické zobrazení průběhu predikce DDDT bez zahrnutí vlivu venkovní teploty na pondělí 23.11.1998 a úterý 24.11.1998 (lokalita Olomoucka, vzorkovací perioda 30 minut).....</i>	<i>111</i>
<i>Obr. 6.31: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na pondělí 23.11.1998 a úterý 24.11.1998 použitím topné charakteristiky ve tvaru po částech se měnící lineární funkce (lokalita Olomoucka, vzorkovací perioda 30 minut)</i>	<i>112</i>
<i>Obr. 6.32: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na pondělí 23.11.1998 a úterý 24.11.1998 použitím topné charakteristiky ve tvaru kubické křivky (lokalita Olomoucka, vzorkovací perioda 30 minut).....</i>	<i>112</i>
<i>Obr. 6.33: Výsledky ve formě konkrétních hodnot pro předpovědi DDDT na pondělí 23.11.1998 a úterý 24.11.1998 bez zahrnutí resp. se zahrnutím vlivu venkovní teploty (lokalita Olomoucka)</i>	<i>113</i>
<i>Obr. 6.34: Grafické zobrazení průběhu venkovní teploty v období 14.10.-18.10.1996 (lokalita Zlínska, vzorkovací perioda 1 hodina)</i>	<i>114</i>
<i>Obr. 6.35: Grafické zobrazení průběhu predikce DDDT bez zahrnutí vlivu venkovní teploty na čtvrtek 17.10.1996 a pátek 18.10.1996 (lokalita Zlínska, vzorkovací perioda 1 hodina).....</i>	<i>114</i>
<i>Obr. 6.36: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na čtvrtek 17.10.1996 a pátek 18.10.1996 použitím topné charakteristiky ve tvaru po částech se měnící lineární funkce (lokalita Zlínska, vzorkovací perioda 1 hodina).....</i>	<i>115</i>
<i>Obr. 6.37: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na čtvrtek 17.10.1996 a pátek 18.10.1996 použitím topné charakteristiky ve tvaru kubické křivky s vyrovnáním časové řady (lokalita Zlínska, vzorkovací perioda 1 hodina)</i>	<i>115</i>
<i>Obr. 6.38: Výsledky ve formě konkrétních hodnot pro předpovědi DDDT na dny čtvrtek 17.10.1996 a pátek 18.10.1996 bez zahrnutí resp. se zahrnutím vlivu venkovní teploty (lokalita Zlínska)</i>	<i>116</i>
<i>Obr. 6.39: Grafické zobrazení průběhu venkovní teploty v období 30.10.-2.11.1996 (lokalita Zlínska, vzorkovací perioda 1 hodina)</i>	<i>117</i>
<i>Obr. 6.40: Grafické zobrazení průběhu predikce DDDT bez zahrnutí vlivu venkovní teploty na sobotu 2.11.1996 (lokalita Zlínska, vz. perioda 1 hodina).....</i>	<i>117</i>
<i>Obr. 6.41: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na sobotu 2.11.1996 použitím topné charakteristiky ve tvaru kubické křivky (lokalita Zlínska, vzorkovací perioda 1 hodina)</i>	<i>118</i>
<i>Obr. 6.42: Výsledky ve formě konkrétních hodnot pro předpovědi DDDT na sobotu 2.11.1996 bez zahrnutí resp. se zahrnutím vlivu venkovní teploty (lokalita Zlínska)</i>	<i>118</i>

<i>Obr. 7.1: Principiální schéma horkovodu</i>	<i>121</i>
<i>Obr. 7.2: Algoritmus kvalitativně – kvantitativního způsobu řízení dodávky tepla horkovodem</i>	<i>124</i>
<i>Obr. 7.4: Typy spotřebních charakteristik.....</i>	<i>131</i>
<i>Obr. 7.5: Odpovídající typy funkcí poměrných přírůstků spotřeby</i>	<i>132</i>

SEZNAM TABULEK

<i>Tabulka 1: Závislost $\hat{u}^\#$ na velikosti pásma pravděpodobnosti</i>	<i>49</i>
<i>Tabulka 2: Váhy klouzavých průměrů</i>	<i>55</i>
<i>Tabulka 3: Hodnoty V_k pro uvažovanou časovou řadu DDDT – určení řádu klouzavých průměrů</i>	<i>57</i>
<i>Tabulka 4: Hodnoty transformačního parametru λ s odpovídajícími transformacemi</i>	<i>59</i>
<i>Tabulka 5: Vlastnosti ACF a PACF pro různé modely typu ARMA</i>	<i>69</i>

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

<i>symbol</i>	<i>jednotka</i>	<i>význam</i>
<u>Matice</u>		
\mathbf{A}	$t^2 \text{ hod}^{-2}$	matice autokovariančních funkcí pro výpočet parametrů autoregrese
<u>Vektory</u>		
\vec{a}	$t \text{ hod}^{-1}$	vektor rozdílu mezi skutečnou hodnotou a zpětně predikovanou hodnotou (vektor reziduí)
\vec{h}	1	vektor hodnot koeficientů normování
\vec{w}	$t \text{ hod}^{-1}$	vektor hodnot filtrované časové řady
\vec{y}	$t^2 \text{ hod}^{-2}$	vektor hodnot autokovarianční funkce, využívaný při výpočtu parametrů autoregrese
\vec{z}	$t \text{ hod}^{-1}$	vektor hodnot časové řady
\vec{z}^+	$t \text{ hod}^{-1}$	vektor hodnot predikované časové řady
\vec{z}^{tr}	$t \text{ hod}^{-1}$	vektor hodnot transformované časové řady
\vec{z}^{tr+}	$t \text{ hod}^{-1}$	vektor hodnot transformované predikované časové řady
$\vec{z}^{(\pm)}$	$t \text{ hod}^{-1}$	vektor hodnot horního a dolního pásma pravděpodobnosti
$\vec{\phi}$	1	vektor parametrů autoregrese nesezónní
$\vec{\phi}^\#$	1	vektor zobecněných parametrů autoregrese
$\vec{\phi}^+, \vec{\phi}^{++}$	1	vektory pomocných parametrů autoregrese
$\vec{\Phi}$	1	vektor parametrů autoregrese sezónní
$\vec{\theta}$	1	vektor parametrů klouzavého součtu nesezónního
$\vec{\Theta}$	1	vektor parametrů klouzavého součtu sezónního

Jednoduché proměnné

a	$t \text{ hod}^{-1}$	rozdíl mezi skutečnou hodnotou a zpětně predikovanou, reziduum
b	1	časový posuv, vztahující se k minulosti
B	1	operátor posuvu zpět
$B^\#$	1	maximální časový posuv, vztahující se k minulosti
d	1	počet nesezónních diferencí
D, D^*	1	počet sezónních diferencí
g, i, j	1	pomocná proměnná
h	1	hodnota koeficientu normování
h^+	1	hodnota predikovaného koeficientu normování
k	1	zpoždění autokovarianční a autokorelační funkce
K	1	maximální zpoždění autokovarianční a autokorelační funkce
L	1	maximální časový předstih
\bar{w}	$t \text{ hod}^{-1}$	aritmetický průměr časové řady \bar{w}
n	1	počet hodnot časové řady po filtraci
N	1	počet hodnot časové řady
p	1	počet parametrů nesezónní autoregrese
$p^\#$	1	počet zobecněných parametrů nesezónní autoregrese
p^+, p^{++}	1	počet pomocných parametrů nesezónní autoregrese
P	1	počet parametrů sezónní autoregrese
q	1	počet parametrů nesezónního klouzavého součtu
Q	1	počet parametrů sezónního klouzavého součtu
r_k	1	hodnota autokorelační funkce
c_k	$t^2 \text{ hod}^{-2}$	odhad hodnoty autokovarianční funkce

c'_k	$t^2 \text{ hod}^{-2}$	odhad hodnoty modifikované autokovarianční funkce
s, s^*	1	perioda sezónnosti
t	hod	čas
u	1	časový předstih
$\hat{u}^\#$	1	kvantil normálního rozdělení
U	%	pásma pravděpodobnosti
V	$t \text{ hod}^{-1}$	hodnota rozptylové funkce časové řady
w	$t \text{ hod}^{-1}$	hodnota filtrované časové řady
y	$t^2 \text{ hod}^{-2}$	hodnota autokovarianční funkce
z	$t \text{ hod}^{-1}$	hodnota časové řady
z^+	$t \text{ hod}^{-1}$	predikovaná hodnota časové řady
z^{tr}	$t \text{ hod}^{-1}$	hodnota transformované časové řady
z^{tr+}	$t \text{ hod}^{-1}$	predikovaná hodnota transformované časové řady
$z^{(\pm)}$	$t \text{ hod}^{-1}$	hodnota horního a dolního pásma pravděpodobnosti
z_i^{den+}	$t \text{ hod}^{-1}$	predikovaná hodnota odběru tepla pro i -tou hodinu daného dne,
z_i^{den+*}	$t \text{ hod}^{-1}$	korigovaná hodnota předpovědi odběru tepla pro i -tou hodinu daného dne,
S_i^{den}	1	korekční koeficient pro i -tou hodinu daného dne
z_t^{filtr}	$t \text{ hod}^{-1}$	hodnota odběru tepla v čase t s odfiltrováním vlivu venkovní teploty,
z_t^{kor-}	$t \text{ hod}^{-1}$	korekční hodnota odběru tepla v čase t zahrnující vliv venkovní teploty
z_t^{filtr+}	$t \text{ hod}^{-1}$	predikovaná hodnota odfiltrované řady odběru tepla v čase t ,
$z_{stř}$	$t \text{ hod}^{-1}$	střední hodnota časové řady
ϕ	1	parametr autoregrese nesezónní

$\phi^{\#}$	1	zobecněný parametr autoregrese
ϕ^+, ϕ^{++}	1	pomocné parametry autoregrese
Φ	1	parametr autoregrese sezónní
λ	1	transformační parametr
θ	1	parametr klouzavého součtu nesezónního
θ_0	1	všeobecná konstanta
$\theta^{\#}$	1	zobecněný parametr klouzavého součtu
Θ	1	parametr klouzavého součtu sezónního
σ^2	t ² hod ⁻²	rozptyl
ψ	1	koefficient pravděpodobnostní funkce
∇	1	operátor diferencí
α, β	1	koefficienty

Pozn.: symbolem * a ** jsou rozlišeny dvě časové řady

- * řada hodnot výkonů DDDT SCZT v jednotlivých hodinách
- ** řada hodnot odběru tepla za 1 den

1 ÚVOD

Předkládaná práce se zabývá studiem algoritmů řízení ve výrobě a rozvodu tepla. Tematicky tedy spadá do oblasti teplotnictví, které je jedním z důležitých odvětví mající vliv na životní úroveň a životní prostředí obyvatel a které v souvislosti se stále rostoucími cenami energií neustále nabývá na významu. Hlavní pozornost je věnována soustavám centralizovaného zásobování teplem (v anglosaské literatuře District Heating Systems), které se staly nedílnou součástí mnoha měst. Z hlediska systémového přístupu můžeme chápat tyto soustavy jako technologické řetězce skládající se ze tří základních článků:

- výroba tepelné energie,
- doprava+distribuce tepla,
- spotřeba tepelné energie.

Ve své doktorské práci se soustředuji na využití předpovědi časových řad při řízení technologického procesu.

Důkladná analýza časových řad a následná předpověď jejich budoucího chování vede ke zlepšení úrovně řízení technologického procesu. Aplikaci takovéto předpovědi je možno najít i při řízení v soustavě centralizovaného zásobování teplem (SCZT), jmenovitě při zajišťování dodávky tepla – řízení tepelného výkonu horkovodu.

Základním vstupním údajem pro přípravu provozu SCZT je znalost potřeby tepla. Pojmem potřeba tepla rozumíme okamžitý tepelný výkon požadovaný nebo odebíraný spotřebitelem. Potřebu tepla lze rozdělit takto:

- závislá na venkovní teplotě
 - vytápění
 - větrání
 - klimatizace
- prakticky nezávislá na venkovní teplotě
 - příprava TUV
 - příprava pokrmů
 - výrobní účely

S tímto pojmem úzce souvisí pojem spotřeba tepla, který vyjadřuje tepelnou energii dodanou spotřebiteli za určitý časový interval, zpravidla za den nebo rok.

Průběh potřeby tepla a spotřebu tepla je možno znázornit pomocí diagramů potřeby tepla. Mezi nejdůležitější patří:

- **denní diagram dodávky (potřeby) tepla - DDDT**, který vyjadřuje průběh potřebného tepelného výkonu během dne (viz Obr. 5.1)
- diagram trvání potřeby tepla – pořadnice ukazují potřebu tepla, její vzdálenost od počátku pak trvání příslušné potřeby tepla. Existují diagramy trvání potřeby tepla denní a roční.

Takové diagramy mají zásadní důležitost při technických a ekonomických úvahách. Proto předpověď průběhů těchto diagramů má význam pro krátkodobé a dlouhodobé plánování výroby tepla. Podle časového průběhu potřeby tepla lze posuzovat otázku špičkových zdrojů a zejména otázku optimálního rozdělování zatížení mezi spolupracující výrobní zdroje a výrobní jednotky uvnitř těchto zdrojů.

Při výpočtech předpovědi časových řad lze využít různých metod řešení, jako jsou např. řešení pomocí lineárních modelů, řešení pomocí nelineárních modelů, metoda spektrální analýzy, neuronové sítě atd.

V minulosti vzniklo velké množství prací, které řeší predikci DDDT a její využití při řízení dodávky tepla či elektrické energie. Většina těchto prací je však založena na hromadném zpracování velkého počtu dat. Tento postup se však vyznačuje jednou velkou nevýhodou, která vede ke zkreslení a tím k nepřesné předpovědi budoucího průběhu DDDT. Tato nevýhoda spočívá v neaktuálnosti zpracovávaných dat. Z tohoto důvodu je výhodné pro predikci DDDT použít metod předpovědi podle metodologie Box-Jenkinse. Tato metoda pracuje jen s určitým počtem hodnot, které jsou každou vzorkovací periodu aktualizovány.

Uvažovaná práce spadá do koncepce řešení „Návrhu řízení rozlehlých teplotárenských soustav“, který je dlouhodobě řešen pod vedením školitele a finančně byl a je podporován Grantovou agenturou České republiky (Grant č. 101/01/0345 - „Cost effective and environmental operation of district heating systems by means of advanced

control algorithms“ respektive Grant č. 101/06/0920 – „Vývoj a využití řídicích algoritmů vyšší úrovně pro řízení teplotních soustav jako nástroje pro snižování cen energií a zlepšování životního prostředí“). Zájem o výsledky projeví energetické podniky, navázána je perspektivní spolupráce s United Energy, a. s. Most-Komořany, Elektrárnou Hodonín, Teplárnou Otrokovice a Teplárnou Olomouc.

1.1 Struktura disertační práce

Abychom předkládanou práci zpřehlednili pro široký okruh čtenářů byla rozdělena do 8 základních částí.

První část podává úvodní informaci o tématu a struktuře disertační práce.

Současný stav řešené problematiky předpovědi časových řad je detailně popsán v *kapitole druhé*.

Ve třetí části jsou formulovány hlavní cíle doktorské disertační práce.

Cílem *čtvrté kapitoly* je poskytnout přehled o základních pojmech z oblasti modelování různých typů časových řad, dále z oblasti předpovědi časových řad včetně popisu metody Box-Jenkinse.

V kapitole páté jsou popsány jednotlivé fáze výstavby modelu časové řady. Tyto fáze jsou pak prakticky ilustrovány na konkrétní časové řadě. Kapitola obsahuje také popis metodologie pro zahrnutí nepravidelných kalendářních vlivů a zahrnutí vlivu venkovní teploty do předpovědi DDDT.

Šestá část, která je nazvána experimentální, je věnována popisu výpočetního programu pro předpověď DDDT. Součástí této kapitoly jsou pak konkrétní výsledky predikce získané pomocí předloženého programu.

Přehled o možnostech využití výsledků disertační práce podává *kapitola sedmá*.

Závěrečná část, *kapitola osmá*, shrnuje celou předkládanou práci a popisuje naplnění jednotlivých cílů.

2 SOUČASNÝ STAV PROBLEMATIKY – LITERÁRNÍ REŠERŠE

Předkládaná práce řeší problémy předpovědi průběhu časových řad s aplikacemi při řízení technologického procesu v reálném čase. Konkrétně se jedná o využití predikce denního diagramu dodávky tepla (DDDT) při řízení v soustavě centralizovaného zásobování teplem (SCZT), jmenovitě při zajišťování dodávky tepla – řízení tepelného výkonu horkovodu. I když se pojem predikce časových řad v současnosti objevuje ve všech oborech lidské činnosti, v oblasti teplotnictví je využití takových předpovědí hodně opomíjeno. V minulosti vznikaly některé práce, které řešily predikci DDDT a její využití při řízení dodávky tepla či elektrické energie. Většina těchto prací byla však založena na hromadném zpracování velkého počtu dat. Tento postup se však vyznačoval velkou nevýhodou, která vedla ke zkreslení a tím k nepřesné předpovědi budoucího průběhu DDDT. Tato nevýhoda spočívala v neaktuálnosti zpracovávaných dat. Z tohoto důvodu je nutné pro predikci DDDT použít dalších metod předpovědi, tak aby došlo k jednoznačnému zlepšení úrovně řízení.

2.1 Metody předpovědi časových řad

Při výpočtech předpovědi časových řad lze využít velkého počtu prediktivních modelů a různých metod řešení. Prakticky je můžeme rozdělit do tří kategorií: klasický (nebo statistický) přístup, metody založené na technice umělé inteligence a ostatní přístupy.

První možností analýzy a následně výpočtu predikce časových řad je použití statistických metod. Sem patří metoda extrapolace trendů (kvadratická, exponenciální, polynomičká), metoda klouzavých průměrů, lineární a nelineární modely, metoda spektrální analýzy, metody založené na Kalmanověm filtru, Wintersonův model, lineární programování, nelineární regrese, model ARFIMA (autoregrese fraktálně integrovaného klouzavého průměru), TAR model (Threshold autoregrese) a další. Mezi nejdůležitější a nejpoužívanější modely umožňující popis a tedy i predikci časových řad řadíme model autoregrese integrovaného klouzavého součtu (ARIMA – Autoregressive Integrated Moving Average) nebo někdy označovaný jako integrovaný smíšený model.

Popularitě vděčí zejména díky dobře známé Box-Jenkinsově metodologii. Tato teorie byla vyvinuta pány G.E.P. Boxem a G.M. Jenkinsem [Box & Jenkins, 1976] před více jak 30 lety a řadí se již ke klasickým metodám, která je mezi prognostiky velmi oblíbená. Jelikož tato metoda v praxi dosahuje velmi dobrých výsledků, byla v této práci zvolena za základ výpočtu predikce. Pro popsání diskrétní časové řady tato teorie používá lineárního modelu tzn., že matematický výraz ve tvaru polynomu je maximálně prvního stupně. Matematický lineární model umožňuje popsat chování časové řady. Pokud průběh zkoumané časové řady neobsahuje trend, lze použít modelu autoregrese (AR - Autoregressive), modelu klouzavého součtu (MA – Moving Average) nebo modelu smíšeného ARMA. Časovou řadu, která vykazuje stoupající nebo klesající trend nebo cyklický průběh, popisujeme modelem ARI, modelem IMA nebo modelem ARIMA. Podrobnější pohled do zmíněné problematiky dávají například publikace [Cipra, 1986], [Anděl, 1976].

Druhou relativně novější skupinu tvoří metody založené na technice umělé inteligence, které zaznamenávají v posledních letech velký rozmach s mnoha aplikacemi. Matematici se v tomto případě obrátili na přírodu a na základě analogie vytvořili dva přístupy. Prvním jsou umělé neuronové sítě a druhým genetické algoritmy. Dále do této skupiny můžeme zahrnout také expertní systémy, využití fuzzy logiky, nebo různě kombinované systémy např. neurofuzzy modely. Největší pozornost vzbuzuje především využití umělých neuronových sítí. Umělá neuronová síť vychází z poznatků biologie a využívá principů, kterými se řídí lidský mozek. Pomocí zjednodušených modelů činnosti lidského mozku lze sestavit umělou neuronovou síť. První práce uveřejnil W.S. McCulloch už v první polovině 20. století. K většímu rozmachu umělých neuronových sítí došlo až po vytvoření výpočetní metody „backpropagation“. Šlo o práci autorů D. Rumelharta, G. Hinton, R. Williamse. Uveďme např. práce [Hinton, 1992], [Hinton, 2000] nebo [Minai & Williams, 1990]. Z česky psaných prací jmenujme například [Novák, 1998]. Analogie z biologie je patrná také v případě genetických algoritmů. Řešení problému pomocí genetických algoritmů probíhá podobně jako vývoj populace nějakého živočišného druhu. Přežívající vybraní jedinci a potomci rodičů jiných vybraných jedinců tvoří další generaci řešení přičemž stará generace zaniká. Počítačová realizace genetických algoritmů se začala objevovat v 70. letech 20. století a je spojena se jmény L. Booker, J. Holland a D. Goldberg. Konkrétní studie a klasifikace genetických algoritmů se objevují až později

[Booker a kol., 1989], [Golberg, 1994]. Aplikací se zabývá např. práce [Goldberg & Chie, 1987]. Fuzzy logika je do této skupiny zahrnuta zejména z důvodu, že se hodně využívá v kombinaci s umělými neuronovými sítěmi, kdy vznikají tzv. neurofuzzy aplikace. Teorie fuzzy množin a fuzzy logiky byla vytvořena v roce 1965 L. Zadehem. Podstatou teorie je určení „jak moc“ daný prvek patří do určité množiny. Tato příslušnost prvku k dané množině je charakterizována stupněm příslušnosti, který je měřen v intervalu $\langle 0,1 \rangle$. Takovéto užití míry členství odpovídá v řadě situací lépe nežli užití klasického způsobu zařazování prvků do množiny podle přítomnosti či nepřítomnosti. Podrobnějším popisem teorií fuzzy logiky se zabývají např. práce [Novák, 1990], [Zadeh a kol., 2000], [Navara & Olšák, 2002].

Do třetí kategorie patří všechny ostatní metody predikce, které nemůžeme jednoznačně zahrnout do dvou předchozích skupin. Jednou z mnoha těchto metod je metoda Delphi, která je založena na expertních posudcích. Princip spočívá v dotazování se na názor skupiny odborníků a vyhodnocení jejich odpovědí. Jinou možností predikce je využití wavelet analýzy, která nám umožňuje rozložit časovou řadu na dílčí složky. Nad těmito složkami provedeme predikci podle některé z metod a výslednou předpověď získáme složením jednotlivých predikcí ve stejném časovém okamžiku. Při analýze časových řad obsahující vysoký podíl nelineárních procesů nám může pomoci teorie Elliotových vln. Tato teorie byla vyvinuta již v minulém století R.N. Elliotem, který došel k empirickým poznatkům, že průběh časové řady se podobá a opakuje. Budoucí průběh se určuje z nedokončené Elliotovy vlny.

V poslední době vzniká také velké množství nových návrhů řešení předpovědí, které jsou založeny na kombinaci předchozích uvedených metod. Příkladem je práce [Zhang, 2003], kde autor využívá hybridní metodologii, která kombinuje model ARIMA s použitím umělé neuronové sítě.

Podpůrnou teorií pro výpočet predikce je teorie chaosu a fraktálů. Jedná se zejména o výpočet tzv. Hurstova exponentu nebo fraktální dimenze, který nám umožňuje vyhodnotit, jak je časová řada chaotická. Výpočtem tzv. Lyapunova exponentu můžeme posoudit prediktabilitu respektive spolehlivost predikce. Nalezení a vyhodnocení těchto

exponentů nám dá odpověď, jestli je vůbec vhodné pokračovat v dalších analýzách časových řad.

2.2 Předpověď časových řad s aplikacemi v energetice

V oblasti energetiky se v současné době časové řady a zejména jejich predikce těší velké pozornosti a stávají se významným předmětem výzkumu. Důvodem je zejména fakt, že předpověď takovýchto řad je prvním a nejdůležitějším krokem k plánování dodávky energie. Předpovědi jsou využívány energetickým managementem pro přípravu výroby v elektrárnách, teplárnách a ve výrobních jednotkách uvnitř těchto provozů. Pro různé druhy využití se používá rozdílné délky předpovědi. Existuje dlouhodobá (měsíce, roky), střednědobá (dny) a krátkodobá (hodiny) předpověď. Dlouhodobá a střednědobá předpověď je využívána k plánování kapacity výroby, rozvoje distribuční sítě, údržby zařízení atd. Krátkodobá předpověď je pak požadována pro účel řízení a plánování výroby energetického systému v reálném čase. Předpovědi těchto časových řad mají zásadní důležitost při technických ale zejména ekonomických úvahách.

Energetické časové řady lze v podstatě rozdělit na časové řady spotřeby *elektrické energie* a časové řady *dodávky tepla* (zatížení v soustavách CZT). Hlavním rozdílem mezi elektrickou energií a dodávkou tepla je dopravní zpoždění, které je významné v soustavách CZT a neobjevuje se v rozvodné síti elektřiny. Ovšem podobnost mezi oběma druhy těchto časových řad existuje a proto lze použít stejného typu algoritmů respektive metod řešení výpočtu předpovědi.

Pro předpověď energetických časových řad bylo využito snad všech metod předpovědi uvedených výše a to s nesterpnou mírou úspěchu. Většina aplikací však vznikla v oblasti předpovědi spotřeby elektrické energie. Při aplikacích bylo použito jak metod klasických (statistických) tak metod využívající umělou inteligenci, které zaznamenali v poslední době velký rozmach.

Metody výpočtu předpovědi pomocí statistických metod lze rozdělit do dvou skupin. Do první skupiny patří metody, kde hodnota aktuální spotřeby je dána matematickou kombinací předchozích hodnot. Práce, které lze zařadit do této kategorie, využívají pro předpověď spotřeby elektrické energie například modely typu AR [Mbamalu

& El-Hawary, 1993], ARMA modely [Amjady, 2001], [Nowicka-Zagrajeka & Weron, 2002], nelineární modely [Sadownik & Barbosa, 1999], Treshold AR modely [Huang, 1997] a nebo modely založené na použití Kalmanových filtrů [Infield & Hill, 1998]. Druhou skupinu pak tvoří metody, kde se mimo předchozích hodnot spotřeby využívají minulé nebo aktuální hodnoty nezávislých proměnných (meteorologické vlivy, sociální potřeby). V této kategorii vznikly práce, které se zabývají využitím např. modelu Box-Jenkinse [Tsoi & Kobe, 1983], přenosové funkce Box-Jenkinse [Hagan & Behr, 1987], ARMAX modelů [Yang & Huang, 1998], neparametrické regrese [Charytoniuk a kol., 1998] nebo práce využívající procedury „proložení křivkou“ [Harvey & Koopman, 1993]. Přestože vzniklo velké množství různých alternativ, nejpopulárnější v oblasti statistických metod stále zůstává využití lineární regrese. Aplikací lineární regrese při předpovědi spotřeby elektrické energie se zabývají například práce [Engle a kol., 1992], [Ramanathan a kol., 1997], [Soliman a kol., 1997], [Smith, 2000]. Tyto modely jsou oblíbené z důvodu fyzikální interpretace jednotlivých složek. To dovoluje systémovým operátorům lépe pochopit jejich chování. Zahrnutím vlivu meteorologických veličin do výpočtu předpovědi spotřeby el. energie (pomocí statistických metod) se zabývají články [Al-Hamadi & Soliman, 2004], [El-Keib a kol., 1995], [Nakamura, 1985], [Bolzern & Fronza, 1986] nebo [Takenawa a kol., 1980]. Do kategorie statistických metod lze zahrnout také článek [Ekwue & Short, 1990], kde autoři popisují své zkušenosti s používáním softwaru „Forecaster Master“ při výpočtu předpovědi spotřeby el. energie v energetické soustavě Nigérie.

Jak již bylo uvedeno, v posledních dvou desetiletích dochází k velkému rozvoji metod založených na technologii umělé inteligence. Jejich výhoda spočívá ve faktu, že nepožadují žádnou komplexní matematickou formulaci ani kvantitativní korelaci mezi vstupem a výstupem. Práce, které řeší předpověď spotřeby elektrické energie prostřednictvím metod umělé inteligence lze opět rozdělit do několika skupin. Jedním z nejúspěšnějších oborů umělé inteligence se staly expertní systémy (ES). ES lze chápat jako nějaký výpočetní systém obsahující dobře organizovaný soubor znalostí, který napodobuje odborný problém. První práce zabývající se aplikací expertních systémů při výpočtu předpovědi spotřeby elektrické energie spadají do roku 1988. [Rahman & Bhatnagar, 1988], [Jabbour a kol., 1988]. Cílem těchto prací bylo využít znalostí,

zkušeností a analytického myšlení systémových operátorů. Dalším krokem bylo využití fuzzy logiky v expertních systémech pro předpověď. Tuto problematiku řeší práce [Park & Park, 1989], [Kim a kol., 1995], [Mori & Kobayashi, 1996], [Ranaweera a kol., 1996] a nově také [Žák, 2002]. Dále vznikla práce [Tamini & Egbert, 2000], která popisuje, jak je možné zpřesnit expertní systémy pro předpověď spotřeby elektrické energie využitím nejen fuzzy logiky ale také umělé neuronové sítě. Článek [Ho a kol., 1990] prezentuje konkrétní aplikaci ES při predikci spotřeby elektrické energie v energetické soustavě Taiwanu.

Největší pozornost co se týká oblasti umělé inteligence budí obor umělých neuronových sítí. Jedna z prvních prací která prezentuje využití umělé neuronové sítě při výpočtu předpovědi spotřeby el. energie byla [Lee a kol., 1992]. Park a kolektiv [Park a kol., 1991] navrhuje použití vícevrstevné sítě s jednou vstupní vrstvou, s jednou skrytou a jednou výstupní vrstvou, kde se pro učení sítě využívá jednoduchého algoritmu „Back-Propagation“. Podrobnější popis tohoto učícího algoritmu můžeme najít v monografii [Simon, 1994]. Stejného učícího algoritmu je použito i při předpovědi v práci [Kalaitzakis a kol., 2002]. Krokem vpřed byla implementace adaptivního učícího algoritmu do vícevrstevné neuronové sítě [Ho a kol., 1992]. Autoři článku [Lu a kol., 1993] začlenili jako vstupní data do neuronové sítě mimo minulých hodnot spotřeby také časové údaje (den v týdnu, hodina dne) a hodnotu venkovní teploty v danou hodinu. Problémem vlivu počasí na předpověď spotřeby el. energie se zabývá mimo jiných článků [Chen a kol., 1992]. Papalexopoulos a kolektiv navrhli ve své práci [Papalexopoulos a kol., 1994] zahrnutí dalších vstupních proměnných (sezónní faktor, stupeň chlazení/topení) do jednoduché neuronové sítě. Naopak Mandal a kolektiv [Mandal a kol., 1995] aplikovali pro předpověď spotřeby el. energie umělou neuronovou síť, kde vstupní parametrem byla jen časová řada minulých hodnot spotřeby el. energie. Metoda, která je založena na kombinaci prediktoru umělé neuronové sítě a dvou lineárně regresních prediktorů [Kiarzizis a kol., 1997] byla realizována při předpovědi spotřeby el. energie v energetické soustavě Řecka, konkrétně v dispečerském centru ostrova Kréta. Srovnání výsledků předpovědi pomocí třívrstevné neuronové sítě s reálnými daty v elektrické soustavě Srbska bylo provedeno v článku [Djukanovics a kol., 1995]. V roce 1998 se poprvé setkáváme s využitím nového typu umělé neuronové sítě „Fuzzy neuronová síť“, která je založena na

kombinaci umělé neuronové sítě s fuzzy logikou. Tématikou použití tohoto typu sítě při předpovědi spotřeby elektrické energie se zabývají například články [Papadakis a kol., 1998], [Kodogiannis & Anagnostakis, 1999], [Liang & Cheng, 2002], [Abraham & Nath, 2001]. V posledních letech se aplikací umělých neuronových sítí při řešení problému předpovědi spotřeby el. energie zabývalo více prací a to s rozdílnou úspěšností. Jde zejména o práce [Mastorocostas a kol., 2000], [Yao a kol., 2000], [Zhang & Dong, 2001], [Chen a kol., 2001].

Třetím oborem umělé inteligence jsou genetické algoritmy. Genetické algoritmy reprezentují mocný a robustní přístup k řešení rozsáhlých optimalizačních problémů. Tyto algoritmy byly použity pro výpočet předpovědi spotřeby el. energie např. v pracích [Heine & Neumann, 1994], [Maifeld & Sheble, 1994] nebo [Yang a kol., 1995]. Srinivan, v článku [Srinivan, 1998], použil genetické algoritmy k vývoji optimální struktury umělé neuronové sítě.

Mimo výše uvedené práce, které se dali rozčlenit podle použitých metod vznikla spousta studií, které provádí srovnání výsledků předpovědi spotřeby el. energie podle různých metod. Sem patří například článek [Ramanathan a kol., 1997], kde autoři provedli několik porovnání použití metod statistických a použití umělé neuronové sítě při výpočtu predikce spotřeby el. energie na konkrétní lokalitě. Výsledkem bylo odhalení faktu, že každá metoda dávala lepší výsledky v jiný den týdne. Konfrontaci použití ARIMA modelu, umělé neuronové sítě a fuzzy neuronové sítě provádí příspěvek [Elkateb a kol., 1998].

Mimo zmíněné členění můžeme ještě zmínit práce, kde je navržen model založený na dekompozici časové řady. Tento přístup řešení predikce spotřeby el. energie byl publikován v knize [Bunn & Farmer, 1985] nebo v příspěvku [Pelikán, 2002]

2.3 Předpověď dodávky tepla v soustavách centralizovaného zásobování teplem

Výrobu tepla v SCZT je třeba optimalizovat jednak z hlediska nákladů na palivo a jednak také z hlediska vlivu na životní prostředí. Tato optimalizace spočívá v nalezení vhodné kombinace výrobních zdrojů a výrobních jednotek uvnitř těchto zdrojů. Ovšem před tím než na základě takové optimalizace vznikne plán výroby je třeba určit budoucí

průběh spotřeby tepla – průběh předpovědi denního diagramu dodávky tepla (DDDT). Jak bylo uvedeno v předchozích odstavcích většina aplikací týkající se předpovědi energetických časových řad vznikla v oblasti předpovědi spotřeby elektrické energie. Oblast předpovědi dodávky tepla v soustavách centralizovaného zásobování teplem zůstává zatím v pozadí. Přesto vzniklo několik prací, které se tímto problémem zabývali.

Mezi nejvýznamnější práce na toto téma patří disertační práce [Arvastson, 2001]. Autor vychází z tvrzení, že největší vliv na spotřebu tepla má venkovní teplota vzduchu a sociální potřeby a chování spotřebitelů. Dále říká, že meteorologické vlivy jako vítr, sluneční záření nebo dešťové srážky ovlivňují průběh spotřeby tepla velmi málo. Samozřejmě připouští, že existují další vlivy, které mohou ovlivňovat průběh spotřeby tepla u spotřebitelů, které je však nemožné namodelovat dostatečně přesně a proto jsou takové vlivy součástí stochastické složky. Také nedostatky a nepřesnosti v měření vykazují stochastické chování. Podobným problémem se zabývá také článek [Dotzauer, 2002]. Autor upozorňuje na skutečnost, že nedostatky a nepřesnosti v měřených datech a také nejistota v předpovědi počasí, může způsobit, že podrobné a složité modely pro předpověď spotřeby tepla se stanou bezcennými. V takovém případě jednodušší model může generovat daleko lepší předpověď. Tato úvaha vedla autora k vytvoření poměrně jednoduchého modelu pro předpověď průběhu spotřeby tepla. Jádrem tohoto modelu je opět fakt, že spotřeba tepla může být dostatečně přesně definována jako funkce venkovní teploty vzduchu a sociálních potřeb spotřebitelů.

Další práce [Lehtoranta a kol., 2000] rozděluje faktory mající vliv na spotřebu tepla do tří skupin: lidské faktory, meteorologické vlivy a fyzikální parametry teplotní sítě. Dále uvádí, že nejvýznamnějším faktorem, který ovlivňuje celkovou spotřebu tepla je vliv venkovní teploty vzduchu. Dokonce je tomuto faktoru přisuzován vliv na celkovou spotřebu tepla přibližně 70 procent. Na rozdíl od předchozích dvou prací je tentokrát pro předpověď spotřeby tepla využito umělé neuronové sítě. Konkrétně autoři použili vícevrstevnou síť s učícím algoritmem podle Levenberg-Marquardta. Algoritmus předpovědi založený na umělé neuronové síti použili také autoři článku [Hippert a kol., 2001].

Klasické metody tj. použití modelů typu ARMA resp. ARIMA využívají při předpovědi průběhu spotřeby tepla práce [Wiklund, 1991] respektive [Chavez a kol., 1999]. Prvně jmenovaná práce navrhuje předpovědní model, kde je vstupním parametrem jednak teplota okolí a jednak teplota dodávaného média. U druhé jmenované jde o využití metodologie Box-Jenkinse při předpovědích budoucího průběhu spotřeby energie v lokalitě severního Španělska (Asturie) v letech 1997-98.

Předkládanou tematikou předpovědi DDDT při řízení dodávky tepla horkovodem se zabývaly některé disertační práce vypracované na VUT v Brně. Velmi podobné téma zpracoval Dostál [Dostál, 1986]. Tato práce však vznikla už před 18 lety a dostatečně nepostihuje nepravidelné kalendářní vlivy a vlivy meteorologických veličin na spotřebu tepla.

Souhrnně lze konstatovat, že předpověď časových řad a zejména pak předpověď energetických časových řad má velký význam při řízení technologického procesu a to jak z pohledu ekonomických úspor tak i z pohledu ekologie provozu. Z výše uvedeného přehledu, který zdaleka nemůže být úplný, lze také prohlásit, že pro řešení problematiky předpovědi časových řad s aplikacemi v energetice lze použít velké množství různých metod.

Je třeba však opět zdůraznit skutečnost, že většina aplikací vznikla v oblasti předpovědi spotřeby el. energie a že oblast řešení předpovědi spotřeby (dodávky) tepla zůstává zatím v pozadí. I proto je téma předkládané práce stále velmi aktuální a navržený model předpovědi průběhu DDDT, který je založen na metodologii Box-Jenkinse a zahrnuje také vlivy meteorologických veličin se může stát vhodným nástrojem pro energetické podniky.

3 CÍLE DISERTAČNÍ PRÁCE

Cílem disertační práce je navrhnout a rozpracovat metodu předpovědi denního diagramu dodávky tepla (DDDT) takovým způsobem, aby byla použitelná při řízení v soustavě centralizovaného zásobování teplem (SCZT), jmenovitě při zajišťování dodávky tepla – řízení tepelného výkonu horkovodu.

Výpočty předpovědi DDDT mají svůj praktický význam nejenom při projekci teplárenských soustav, ale především při samotném provozu. Znalost budoucích hodnot spotřeby tepla v horizontu 24 hodin může být pro dispečery v teplárnách velmi užitečná. Jak je uvedeno níže, taková předpověď vede k eliminaci dopravního zpoždění, k úspoře paliv a energie, což přispívá k ekonomii a ekologii provozu.

Dílčí cíle disertační práce byly s ohledem na možnosti využití stanoveny takto:

1. Sestrojení modelu DDDT podle metodologie Box-Jenkinse
2. Návrh postupu výpočtu předpovědi DDDT
3. Zahrnutí nepravidelných kalendářních vlivů
4. Zahrnutí vlivu meteorologických veličin na spotřebu tepla.
5. Vypracování uživatelského programu pro předpověď DDDT se začleněním vlivu meteorologických veličin a nepravidelných kalendářních vlivů.
6. Testování navržené metody predikce na konkrétních hodnotách DDDT.

Úkolem bude předložit uživatelsky jednoduché prostředí pod operačním systémem Windows, které by se mohlo stát vhodným nástrojem pro provozovatele, případně pro projektanty soustav centralizovaného zásobování teplem a další energetické podniky.

4 TEORETICKÝ RÁMEC

Jak již bylo řečeno, v minulosti vzniklo nepřehledné množství prací, které řeší predikci DDDT a její využití při řízení dodávky tepla či elektrické energie. Většina těchto prací je však založena na hromadném zpracování velkého počtu dat. Tento postup se však vyznačuje jednou velkou nevýhodou, která vede ke zkreslení a tím k nepřesné předpovědi budoucího průběhu DDDT. Tato nevýhoda spočívá v neaktuálnosti zpracovávaných dat. Z tohoto důvodu je výhodné pro predikci DDDT použít metod předpovědi podle metodologie Box-Jenkinse. Tato metoda pracuje jen s určitým počtem hodnot, které jsou každou vzorkovací periodu aktualizovány. Výše zmíněná metodologie byla poprvé publikována již v 60. letech a kompletně sepsána v roce 1976 v knize [Box & Jenkins, 1976]. Americký autor G. Box a angličan G. Jenkins (odtud název Box-Jenkinsova metoda) zde komplexně popsali analýzu časových řad, jejich predikci a využití při řízení. Další publikace [Anderson 1976] a [Montgomery & Johnson, 1976] se přehledně zabývají problematikou předpovědi podle Box-Jenkinse a přinášejí také srovnání s jinými metodami predikce.

Boxův-Jenkinsov přístup bere za základní prvek konstrukce modelu časové řady reziduální složku, která může být tvořena korelovanými (závislými) náhodnými veličinami. Tato metodologie tedy nejen může zpracovávat časové řady s navzájem závislými pozorováními, ale dokonce těžiště jejich postupů spočívá právě ve vyšetřování těchto závislostí neboli v tzv. korelační analýze. Uvedená dnes již klasická metoda umožňuje modelovat i řady s trendovým nebo sezónním charakterem. Tyto řady úspěšně zvládá pomocí tzv. integrovaných modelů ARIMA a tzv. sezónních modelů, v nichž trendová nebo sezónní složka může být modelována stochasticky.

4.1 Základní pojmy a aparát Boxovy-Jenkinsovy metodologie

Cílem úvodní kapitoly je na jedné straně objasnit některé důležité pojmy obecně platné pro modelování různých typů časových řad a na druhé straně podat přehled o lineárních modelech stacionárních časových řad. Zaměříme se tedy na popis základních prostředků podávajících informaci o charakteru stochastického procesu tj. autokorelační

funkce a parciální autokorelační funkce. Při empirické práci s časovými řadami pracujeme s jejich výběrovými protějšky. Dále zde popíšeme modely stacionárních časových řad třídy AR, MA a ARMA, které jsou charakteristické specifickou formou autokorelační funkce a parciální autokorelační funkce, takže jejich odhady lze použít při identifikaci modelu konkrétních analyzovaných časových řad.

4.1.1 *Stochastický proces a stacionarita*

Stochastický proces je v čase uspořádaná řada náhodných veličin. Jedná se tedy o časovou řadu, která je chápána jako konkrétní realizace náhodného procesu.

Jelikož v Boxově-Jenkinsově metodologii lze modelovat pouze stacionární časové řady je nezbytné si pojem *stacionarity* blíže osvětlit. Všeobecně řečeno, stacionarita časové řady znamená, že chování této řady je v jistém smyslu stochasticky ustálené. Většinou se rozlišuje tzv. *striktní stacionarita*, kdy pravděpodobnostní chování příslušného stochastického procesu je invariantní vůči posunům v čase a méně omezující *slabá stacionarita*, kdy příslušný stochastický proces má konstantní střední hodnotu, konstantní rozptyl a kovarianční strukturu druhého řádu invariantní vůči posunům v čase. V praktické analýze časových řad se operuje výhradně se slabou stacionaritou proto ji v dalším budeme jednoduše nazývat stacionaritou. Stacionární proces je tedy rovnoměrně vyvážený (tj. s konstantním rozptylem) kolem konstantní úrovně (tj. má konstantní střední hodnotu), přičemž závislost mezi jeho dvěma libovolnými pozorováními závisí pouze na jejich vzájemné časové vzdálenosti a nikoli na jejich skutečném časovém umístění v řadě. Většina časových řad z praxe vykazuje nestacionární charakter a je tedy nutné pro využití metodologie Box-Jenkinse převést tyto řady na stacionární. To lze uskutečnit pomocí různých transformací (nejčastěji pomocí diferencování).

4.1.2 *Autokovarianční a autokorelační fce.*

Pro stacionární časovou řadu z_t lze vyjádřit autokovarianční funkci mezi veličinami z_t a z_{t-k} jako

$$\gamma_k = C(z_t, z_{t-k}) = E(z_t - \mu)(z_{t-k} - \mu) \quad k = \dots, -1, 0, 1, \dots \quad (4.1)$$

a autokorelační funkci jako

$$\rho_k = \frac{C(z_t, z_{t-k})}{\sqrt{D(z_t) \cdot D(z_{t-k})}} = \frac{\gamma_k}{\gamma_0} = \frac{\gamma_k}{\sigma_z^2} \quad k = \dots, -1, 0, 1, \dots \quad (4.2)$$

kde $\mu = E(z_t)$ je střední hodnota a $\sigma_z^2 = \gamma_0 = D(z_t)$ je rozptyl dané stacionární časové řady.

Autokovarianční a autokorelační fce jsou zřejmě sudé (tzn. $\gamma_k = \gamma_{-k}, \rho_k = \rho_{-k}$), takže pro jejich popis se stačí omezit na $k > 0$. Dále pro autokorelační fci stacionárního procesu platí $\rho_0 = 1$ a $|\rho_k| \leq 1$. Graf autokorelační fce se nazývá korelogram.

Obecně jsou parametry $\mu, \sigma_z^2 = \gamma_0$ a ρ_k neznámé a je třeba je odhadnout. Za předpokladu stacionarity může být střední hodnota pozorované časové řady z_1, \dots, z_n odhadována prostřednictvím výběrového průměru

$$\bar{z} = \sum_{t=1}^n \frac{z_t}{n} \quad (4.3)$$

Odhad autokovarianční fce je pak dán

$$c_k = \sum_{t=1}^{n-k} \frac{(z_t - \bar{z})(z_{t-k} - \bar{z})}{n} \quad k=0, 1, \dots, n-1 \quad (4.4)$$

A z toho vyplývá, že rozptyl $\sigma_z^2 = \gamma_0 = D(z_t)$ může být odhadován pomocí výběrového rozptylu ve tvaru

$$c_0 = \sum_{t=1}^n \frac{(z_t - \bar{z})^2}{n} \quad (4.5)$$

Odhad autokorelační fce je pak dán vztahem

$$r_k = \frac{c_k}{c_0} \quad (4.6)$$

Chování autokorelační fce je v rámci Boxovy-Jenkinsovy metodologie důležitým ukazatelem, neboť napovídá, jaký typ modelu je vhodné pro danou řadu použít.

4.1.3 Parciální autokorelační funkce

Dalším důležitým pojmem Boxovy-Jenkinsovy metodologie je *parciální autokorelační fce* značená jako ρ_{kk} . Parciální autokorelace podávají informaci o korelaci veličin z_t a z_{t-k} očištěné o vliv veličin ležících mezi nimi. Hodnota ρ_{kk} je dána jako podíl determinantů dvou matic ve tvaru:

$$\rho_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}} \quad (4.7)$$

Pro $k=1$, resp. $k=2$ dostáváme hodnoty parciální autokorelační fce ve tvaru (4.8) resp. (4.9).

$$\rho_{11} = \rho_1 \quad (4.8)$$

$$\rho_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \quad (4.9)$$

Pro odhady r_{kk} parciální autokorelační ρ_{kk} se místo počítání komplikovaných determinantů používá rekurentní vztah (4.10)

$$r_{kk} = \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} \cdot r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} \cdot r_j} \quad \text{pro } k > 1 \quad (4.10)$$

kde

$$r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-j} \quad \text{pro } j=1, 2, \dots, k-1 \quad (4.11)$$

$$r_{11} = r_1 \quad (4.12)$$

4.1.4 Proces bílého šumu

Uvažujeme-li stochastický proces jako řadu nekorelovaných náhodných veličin jednoho pravděpodobnostního rozdělení s konstantní střední hodnotou (obvykle nulovou), s konstantním rozptylem a nulovou autokovarianční funkcí pro všechna $k \neq 0$, potom se takový proces označuje jako *proces bílého šumu* nebo jednoduše *bílý šum*. Označujeme ho a_t . Z definice dále vyplývá, že proces bílého šumu je stacionární s autokorelační funkcí ve tvaru

$$\rho_k = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0 \end{cases} \quad (4.13)$$

a parciální autokorelační funkcí ve tvaru

$$\rho_{kk} = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0 \end{cases} \quad (4.14)$$

I když se tento proces prakticky nevyskytuje, hraje důležitou roli jako základní stavební prvek při výstavbě modelů časových řad.

4.1.5 Jednoduché operátory

Jednoduché operátory slouží zejména pro zjednodušení a zestručnění zápisu složitějších modelů. Velmi často používaným je tzv. *operátor zpětného posunutí* B , který představuje zpoždění a je definován jako

$$Bz_t = z_{t-1} \quad (4.15)$$

Příčemž jej lze aplikovat i několikanásobně jako

$$B^j z_t = z_{t-j} \quad (4.16)$$

Jiným důležitým operátorem je tzv. *zpětný diferenční operátor* ∇ . Tento operátor lze zřejmě vyjádřit pomocí operátoru zpětného posunutí B a to ve tvaru

$$\nabla = 1 - B \quad (4.17)$$

neboť

$$\nabla z_t = z_t - z_{t-1} = (1 - B)z_t \quad (4.18)$$

Formálně pak můžeme zapsat například zpětný diferenční operátor druhého řádu ve tvaru

$$\nabla^2 z_t = (1 - B)^2 z_t = (1 - 2B + B^2)z_t = z_t - 2z_{t-1} + z_{t-2} \quad (4.19)$$

4.1.6 Lineární proces

Každý stacionární proces, který neobsahuje deterministickou složku může být vyjádřen jako lineární kombinace řady nekorelovaných stejně rozdělených náhodných veličin. Tato lineární kombinace se označuje jako *lineární proces*.

Lineární proces lze vyjádřit jako

$$z_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots = \sum_{j=0}^{\infty} \psi_j a_{t-j}, \quad \psi_0 = 1 \quad (4.20)$$

Kde a_t je bílý šum s rozptylem σ_a^2 a ψ_j jsou parametry. Při použití operátoru zpětného posunutí B můžeme lineární proces zapsat ve tvaru

$$z_t = \psi(B)a_t \quad (4.21)$$

kde

$$\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots = 1 + \sum_{j=1}^{\infty} \psi_j B^j \quad (4.22)$$

Za jistých podmínek lze lineární proces (4.20) zapsat ve tvaru (4.23), kdy jeho současná hodnota je vyjádřena pomocí jeho minulých hodnot a současné hodnoty bílého šumu. Takový lineární proces se nazývá *invertibilní*.

$$z_t = a_t + \pi_1 z_{t-1} + \pi_2 z_{t-2} + \dots = \sum_{j=0}^{\infty} \pi_j z_{t-j}, \quad \pi_0 = 1 \quad (4.23)$$

Při použití operátoru zpětného posunutí B lze tento proces ekvivalentně zapsat ve tvaru

$$\pi(B)z_t = a_t \quad (4.24)$$

kde

$$\pi(B) = 1 - \pi_1 B - \pi_2 B^2 - \dots = 1 - \sum_{j=1}^{\infty} \pi_j B^j \quad (4.25)$$

Mnohem větší praktický význam než obecný lineární proces mají pro Boxovu-Jenkinsovu metodologii jeho speciální případy (proces klouzavých součtů MA, autoregresní proces AR a smíšený proces ARMA). Tyto procesy vznikají z lineárního procesu zapsaného ve tvaru (4.20) nebo (4.23) vynulováním všech parametrů až na konečný počet. Souvisí to s tím, že v Boxově-Jenkinsově metodologii se důsledně dbá na to, aby používané modely byly konstruovány co nejúsporněji tj. s co nejmenším počtem parametrů. Procesy MA, AR a ARMA, které představují základní stavební prvky Boxovy-Jenkinsovy metodologie budou stručně popsány v následujících kapitolách.

4.1.7 Proces klouzavých součtů

Především je nutné upozornit na to, aby zde nedocházelo k záměně s metodou klouzavých průměrů (viz kap. 5.2.1), používanou pro vyrovnávání časových řad. *Proces klouzavých součtů řádu q* označovaný jako $MA(q)$ je definován jako

$$z_t = a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} = \sum_{j=0}^q \theta_j a_{t-j}, \quad \theta_0 = 1 \quad (4.26)$$

Při použití operátoru zpětného posunutí B můžeme MA proces zapsat ve tvaru

$$z_t = \theta(B)a_t \quad (4.27)$$

kde

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q = 1 + \sum_{j=1}^q \theta_j B^j \quad (4.28)$$

Modely MA vycházejí přímo z lineárního procesu (4.20), liší se pouze tím, že mají konečný počet parametrů ψ . Z této skutečnosti plyne, že všechny modely MA jsou stacionární.

4.1.8 Autoregresní proces

Autoregresní proces řádu p označovaný jako $AR(p)$ je definován jako

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t \quad (4.29)$$

kde současná hodnota procesu je vyjádřena pomocí konečného počtu jeho minulých hodnot a současné hodnoty bílého šumu. Pomocí symboliky operátoru zpětného posunutí B můžeme tento proces psát ve tvaru

$$\phi(B)z_t = a_t \quad (4.30)$$

kde

$$\phi(B) = 1 - \phi_1 B + \phi_2 B^2 + \dots - \phi_p B^p = 1 - \sum_{j=1}^p \phi_j B^j \quad (4.31)$$

je tzv. *autoregresní operátor*.

4.1.9 Smíšený proces

K dosažení větší flexibility při konstrukci aktuální časové řady je někdy výhodné zahrnout do modelu kombinaci předchozích dvou procesů. To pak vede ke vzniku *smíšeného procesu řádu p a q* označovaného jako $ARMA(p,q)$. Je definován jako

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (4.32)$$

Pomocí symboliky operátoru zpětného posunutí B lze tento proces psát ve tvaru

$$\phi(B)z_t = \theta(B)a_t \quad (4.33)$$

kde $\theta(B)$ a $\phi(B)$ byly definovány v (4.28) resp. (4.31)

4.1.10 Nestacionární proces

Mnoho časových řad se kterými se velmi často setkáváme v průmyslu nebo ekonomice vykazují nestacionární charakter. Tato nestacionarita může být způsobena v čase se měnící střední hodnotou procesu či v čase se měnícím rozptylem procesu. Homogenní nestacionární chování může být modelováno například procesem ve tvaru

$$z_t = z_{t-1} + a_t \quad (4.34)$$

Který se nazývá *proces náhodné procházky (random walk process)*. Jde o zvláštní případ procesu $AR(1)$, kde $\phi_1 = 1$. Pomocí operátoru zpětného posunutí jej lze vyjádřit jako

$$(1 - B)z_t = a_t \quad (4.35)$$

Proces náhodné procházky se také nazývá integrovaný proces. Protože jeho první diference je proces bílého šumu, nazývá se jako integrovaný proces řádu jedna a označuje se $I(1)$. V případě, že budeme tento proces (4.35) modifikovat do tvaru

$$(1 - B)^d z_t = a_t \quad (4.36)$$

dostáváme obecnější proces, který je nazýván jako *integrováný proces řádu d* a označuje se jako $I(d)$. Pomocí operátu zpětné diference můžeme tento proces přepsat do tvaru

$$\nabla^d z_t = a_t \quad (4.37)$$

Takových integrovaných procesů se využívá právě při modelování nestacionárních časových řad. Pokud spojíme takový proces s výše uvedeným smíšeným procesem dostáváme tzv. *integrováný smíšený proces řádu p , q a d* označovaný jako $ARIMA(p,q,d)$. můžeme ho pak zapsat ve tvaru

$$\phi(B)w_t = \theta(B)a_t \quad (4.38)$$

kde

$$w_t = \nabla^d z_t \quad (4.39)$$

je d -tá diference modelovaného procesu z_t . Proces (4.38) je stacionární model $ARMA(p,q)$ pro proces w_t . Souhrnně lze model $ARIMA(p,q,d)$ zapsat tedy ve tvaru

$$\phi(B)\nabla^d z_t = \theta(B)a_t \quad (4.40)$$

Při praktické výstavbě modelu $ARIMA(p,q,d)$ se však dává přednost rozpisu (4.38) a (4.39) před souhrnným zápisem (4.40). Ve skutečnosti to znamená, že nejprve se diferencováním analyzované řady z_t zkonstruuje stacionární řada w_t pro niž s vzápětí vybuduje proces $ARMA(p,q)$. Přitom je nutné mít na paměti, že pokud řada z_t je zadána N hodnotami, pak pro řadu w_t máme k dispozici je $N-d$ hodnot.

4.2 Model podle Box-Jenkinse

Model Box-Jenkinse vyjadřuje hodnotu analyzované časové řady z_t v čase t ve tvaru (4.41).

$$z_t = \Phi_p^{-1}(B^s) \cdot \phi_p^{-1}(B) \cdot \Theta_q(B^s) \cdot \theta_q(B) \cdot \nabla_s^{-D} \cdot \nabla^{-d} \cdot a_t \quad (4.41)$$

kde výraz $\Phi_p(B^s)$ je operátor přenosové funkce sezónního modelu autoregrese, který vyjadřuje deterministickou periodickou složku signálu a je definován ve tvaru (4.42).

$$\Phi_p(B^s) = 1 - \Phi_1(B^s) - \Phi_2(B^{2s}) - \dots - \Phi_p(B^{Ps}) \quad (4.42)$$

Výraz $\phi_p(B)$ je operátor přenosové funkce nesezónního modelu autoregrese, který vyjadřuje deterministickou neperiodickou složku signálu a je definován ve tvaru (4.43).

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (4.43)$$

Výraz $\Theta_Q(B^s)$ je operátor přenosové funkce sezónního modelu klouzavého součtu, vyjadřující stochastickou složku signálu, který je definován ve tvaru (4.44).

$$\Theta_Q(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs} \quad (4.44)$$

Výraz $\theta_q(B)$ je operátor přenosové funkce nesezónního modelu klouzavého součtu, vyjadřující stochastickou složku signálu, který je definován ve tvaru (4.45).

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (4.45)$$

Výraz ∇_s^D je operátor zpětné sezónní diference, který je definován jako

$$\nabla_s^D = (1 - B^s)^D \quad (4.46)$$

a umožňuje odstranit periodickou složku signálu a tím provést sezónní filtraci časové řady.

Výraz ∇^d je operátor zpětné nesezónní diference, který je definován jako

$$\nabla^d = (1 - B)^d \quad (4.47)$$

a umožňuje odstranit neperiodickou (trendovou) složku signálu a tím provést nesezónní filtraci časové řady

a_t – je proces bílého šumu

Pro názornost si můžeme hodnotu časové řady z_t v čase t vyjádřit pomocí jednoduchých modelů.

Model sezónní autoregrese, označovaný v literatuře AR (P), který získáme dosazením vztahu (4.42) do vztahu (4.41) při zanedbání ostatních modelů, tj.

$$z_t = \Phi_1 z_{t-s} + \Phi_2 z_{t-2s} + \dots - \Phi_p z_{t-ps} + a_t \quad (4.48)$$

Model nesezónní autoregrese, označovaný v literatuře AR (p), který získáme dosazením vztahu (4.43) do vztahu (4.41) při zanedbání ostatních modelů, tj.

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots - \phi_p z_{t-p} + a_t \quad (4.49)$$

Model sezónního klouzavého součtu, označovaný v literatuře MA (Q), který získáme dosazením vztahu (4.44) do vztahu (4.41) při zanedbání ostatních modelů, tj.

$$z_t = a_t - \Theta_1 a_{t-s} - \Theta_2 a_{t-2s} - \dots - \Theta_Q a_{t-Qs} \quad (4.50)$$

Model nesezónního klouzavého součtu, označovaný v literatuře MA (q), který získáme dosazením vztahu (4.45) do vztahu (4.41) při zanedbání ostatních modelů, tj.

$$z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4.51)$$

Integrovaný sezónní model, označovaný v literatuře I (D), pro D=1 dostáváme

$$\nabla_s^D z_t = (1 - B^s)^D z_t = (1 - B^s) z_t = z_t - z_{t-s} \quad (4.52)$$

Integrovaný nesezónní model, označovaný v literatuře I (d), pro d=1 dostáváme

$$\nabla^d z_t = (1 - B)^d z_t = (1 - B) z_t = z_t - z_{t-1} \quad (4.53)$$

Obecný model Box-Jenkinse, vyjádřený vztahem (4.41), umožňuje kombinace jednotlivých modelů, například ARMA(P,Q), ARIMA(P,Q,D), ARMA(p,q), ARIMA(p,q,d), ARIMA(P,p,Q,q,D,d), popřípadě jejich dílčích částí, například ARI(P,D), IMA(Q,D), ARI(p,d), IMA(q,d), atd.

Zavedeme-li substituci

$$F = \Phi_p^{-1}(B^s) \cdot \phi_p^{-1}(B) \cdot \Theta_Q(B^s) \cdot \theta_q(B) \cdot \nabla_s^{-D} \cdot \nabla^{-d} \quad (4.54)$$

potom rovnici (4.41) lze psát ve tvaru

$$z_t = F \cdot a_t \quad (4.55)$$

Pro predikci pak model (4.55) vyjádříme ve tvaru

$$z_{t+u} = F \cdot a_{t+u} \quad (4.56)$$

pro $u = 1, 2, \dots, L$, kde u je časový předstih a L je maximální časový předstih.

4.2.1 Obecný postup výpočtu predikce podle Box-Jenkinse

Vzorce a postup výpočtu v této kapitole jsou převzaty z [Box & Jenkins, 1976]. Pro výpočet predikce časové řady je nutné zadat hodnoty časové řady z_t a počet hodnot časové řady N .

Z důvodů nesezónní resp. sezónní filtrace časové řady je nutné zadat počet nesezónních diferencí d , počet sezónních diferencí D a periodu sezónnosti s .

Časová řada z_t je filtrována na stacionární řadu w_t výrazem

$$w_t = \nabla^d \nabla_s^D z_t = (z_t - z_{t-d}) - (z_{t-sD} - z_{t-d-sD}) \quad (4.57)$$

Je nutné opět zdůraznit, že tento výraz platí jen pro $d + sD < t < N$, protože po filtraci máme k dispozici pouze n hodnot časové řady.

$$n = N - d - sD \quad (4.58)$$

Dále se provede výpočet odhadů statistických charakteristik stacionární časové řady w_t , tj. aritmetického průměru \bar{w} , rozptylu σ_w^2 , autokovarianční funkce c_k a autokorelační funkce r_k .

Pro výpočet je nutné též zadat maximální zpoždění autokovarianční a autokorelační funkce K , které musí splňovat nerovnost

$$K \geq p + q \quad (4.59)$$

Aritmetický průměr \bar{w} je definován jako

$$\bar{w} = \frac{1}{n} \sum_{t=1}^n w_t \quad (4.60)$$

Rozptyl σ_w^2 je definován jako

$$\sigma_w^2 = \frac{1}{n} \sum_{t=1}^n (w_t - \bar{w})^2 \quad (4.61)$$

Autokovarianční funkce c_k stacionárního náhodného procesu je definována jako

$$c_k = \sum_{t=1}^{n-k} \frac{(w_t - \bar{w})(w_{t+k} - \bar{w})}{n} \quad k=0, 1, \dots, K \quad (4.62)$$

Autokorelační funkce r_k stacionárního náhodného procesu je definována jako

$$r_k = \frac{c_k}{c_0} \quad k=0, 1, \dots, K \quad (4.63)$$

Další postup predikce časové řady spočívá ve výpočtu parametrů autoregrese ϕ_1, \dots, ϕ_p resp. Φ_1, \dots, Φ_2 a parametrů klouzavého součtu. $\theta_1, \dots, \theta_p$ resp. $\Theta_1, \dots, \Theta_2$. Jelikož odstraníme periodické složky (sezónnost) filtrováním časové řady podle vzorce omezíme se jen na výpočet parametrů ϕ_1, \dots, ϕ_p a $\theta_1, \dots, \theta_2$. Pro výpočet se používají dříve získané výsledky. Dále je nutné zadat počet parametrů autoregrese p a počet parametrů klouzavého součtu q .

Výpočet parametrů autoregrese - ϕ

Je-li $p > 0$, řešíme soustavu p lineárních rovnic podle rovnice

$$\mathbf{A} \cdot \vec{\phi} = \vec{y} \quad (4.64)$$

kde

$$A_{ii} = c_{|q+i-j|} \quad (4.65)$$

$$y_i = c_{|q+i|} \quad \text{pro } i, j = 1, 2, \dots, p. \quad (4.66)$$

Řešením této soustavy lineárních rovnic dostaneme parametry ϕ_1, \dots, ϕ_p .

Výpočet parametrů klouzavého součtu θ

Provedeme nejdříve modifikaci autokovarianční funkce c_k podle vzorce

$$c'_j = \begin{cases} \sum_{i=0}^p \sum_{g=0}^p \phi_i \phi_g c_{|j+i-g|} & \text{pro } p > 0 \\ c_j & \text{pro } p = 0 \end{cases} \quad (4.67)$$

kde $j = 0, 1, \dots, q$ a $\phi_0 = -1$. Vlastní výpočet parametrů klouzavého součtu provádíme iterativním postupem podle vzorců (4.68) a (4.69).

$$\sigma_a^2 = \frac{c'_0}{1 + \theta_1^2 + \dots + \theta_q^2} \quad (4.68)$$

$$\theta_j = - \left(\frac{c'_j}{\sigma_a^2} - \theta_1 \theta_{j+1} - \theta_2 \theta_{j+2} - \dots - \theta_{q-j} \theta_q \right) \quad (4.69)$$

Po výpočtu parametrů autoregrese a parametrů klouzavého součtu se dále provádí výpočet konstanty θ_0 podle vzorce (4.70) a výpočet počátečního odhadu rozptylu reziduí $\hat{\sigma}_a^2$ podle vzorce (4.71).

$$\theta_0 = \begin{cases} \bar{w} \left(1 - \sum_{i=1}^p \phi_i \right) & \text{pro } p > 0 \\ \bar{w} & \text{pro } p = 0 \end{cases} \quad (4.70)$$

$$\widehat{\sigma}_a^2 = \begin{cases} c'_0 & \text{pro } q > 0 \\ c_0 - \sum_{i=1}^p \phi_i c_i & \text{pro } q = 0 \end{cases} \quad (4.71)$$

Počet parametrů autoregrese p a klouzavého součtu q volíme podle tvaru statistických charakteristik nebo provádíme automatickou volbu kombinací hodnot p a q . Kriteriem pro volbu nejvhodnějšího modelu je obvykle minimální hodnota rozptylu reziduí $\widehat{\sigma}_a^2$ a minimální hodnoty p a q . Otázkou určení řádu procesu autoregrese resp. procesu klouzavých součtů se zabývá kapitola 5.2.4 resp. 5.2.6.

Pro výpočet predikce časové řady je třeba zadat hodnotu maximálního časového předstihu L a maximálního časového posuvu, vztahujícího se k minulosti B^* . Ze zadaných údajů a z hodnot dříve vypočtených provedeme nejdříve výpočet zobecněných parametrů $\phi_1^* \cdots \phi_p^*$ a potom vypočítáme predikované hodnoty časové řady a pásmo pravděpodobnosti výskytu predikovaných hodnot časové řady.

Počet hodnot L časové řady, které chceme předpovědět je libovolný. Je však vhodné dodržet podmínku, že $L < N/4$.

Pro výpočet zobecněných parametrů $\phi_1^* \cdots \phi_p^*$ je nutné nejdříve vypočítat hodnoty $\phi_1^+, \phi_2^+, \dots, \phi_{p^+}^+$, které jsou vyjádřeny ve výrazu (4.72) a jsou vypočteny podle vzorce (4.73).

$$\phi_{p^+}^+(B) = \Phi_P(B^s) \phi_p(B) = 1 - \phi_1^+ B - \phi_2^+ B^2 - \dots - \phi_{p^+}^+ B^{p^+} \quad (4.72)$$

$$\phi_{j+si}^+ = \sum_{i=0}^P \sum_{j=0}^P \Phi_i \phi_j \quad (4.73)$$

kde $\Phi_0 = -I$ a $\phi_0 = -I$.

Zobecněné parametry $\phi_1^* \cdots \phi_p^*$ jsou pak vyjádřeny ve výrazu (4.74).

$$\phi_p^*(B) = \nabla^d \nabla_s^D \phi_{p^+}^+(B) = 1 - \phi_1^* B - \phi_2^* B^2 - \dots - \phi_p^* B^{p^*} \quad (4.74)$$

kde $p^+ = p + sP$ a $p^* = p^+ + d + sD$.

Vlastní výpočet zobecněných parametrů $\phi_1^* \cdots \phi_p^*$ pak probíhá ve třech částech:

a)

$$\phi_j^{++} = \begin{cases} \phi_j^+ & \text{pro } 0 \leq j < s \\ \phi_j^+ - \phi_{j-s}^+ & \text{pro } s \leq j \leq p^+ \\ -\phi_{j-s}^+ & \text{pro } p^+ < j \leq p^+ + s \end{cases} \quad (4.75)$$

b) Výpočet (4.75) opakujeme D -krát a to tak, že po každé iteraci (4.75) zaměníme

ϕ_j^{++} za ϕ_j^+ a $p^{++} = p^+ + s$ za p^+ . Takto obdržíme hodnoty ve tvaru $\nabla_s^D \phi_{p^+}^+(B)$.

c) Podobně výpočet (4.75) opakujeme d -krát s hodnotou $s=1$. Takto získáme

hodnoty ve tvaru $\nabla^d \nabla_s^D \phi_{p^+}^+(B)$ tzn. hodnoty $\phi_1^* \cdots \phi_p^*$.

Výpočet predikovaných hodnot

Hodnoty predikované časové řady \bar{z}^+ vypočítáme ze vzorce (4.76).

$$z_{N-b+u}^+ = \theta_0 + \sum_{i=1}^{p+sP+d+sD} \phi_i^* z_{N-b-i+u} - \sum_{j=1}^{q+sQ} \theta_j a_{N-b-j+u} \quad (4.76)$$

kde

$$z_{N-b-i+u} = \begin{cases} z_{N-b-i+u}^+ & \text{pro } u > i \\ z_{N-b-i+u} & \text{pro } u \leq i \end{cases} \quad (4.77)$$

$$a_{N-b-j+u} = \begin{cases} 0 & \text{pro } u > j \\ z_{N-b-j+u} - z_{N-b-j+u}^+ & \text{pro } u \leq j \end{cases} \quad (4.78)$$

kde $u = 1, 2, \dots, L$ a $b = 0, 1, \dots, B^*$.

Výpočet pásma pravděpodobnosti

Pásma pravděpodobnosti je dáno výrazem (4.79).

$$z_{N-b+u}^{(\pm)} = z_{N-b+u}^+ \pm \hat{u}^{\#} \sqrt{V(u)} \quad (4.79)$$

kde $\hat{u}^{\#} = \hat{u}_{\varepsilon^*/2}$ je dáno podle zvoleného pásma pravděpodobnosti U (tj. např. 50%, 90%, 95%), $\hat{u}_{\varepsilon^*/2}$ je kvantil normálního rozdělení, $\varepsilon^* = 1-U$.

Číselné hodnoty $\hat{u}^{\#}$ pro některé velikosti pásma pravděpodobnosti jsou názorně zobrazeny v tabulce 1.

Tabulka 1: Závislost $\hat{u}^{\#}$ na velikosti pásma pravděpodobnosti

U [%]	50	75	90	95	99
$\hat{u}^{\#}$	0,675	1,15	1,645	1,96	2,576

Rozptylovou funkci $V(u)$ vypočteme z výrazu (4.80)

$$V(u) = \sigma_a^2 \sum_{j=0}^{u-1} \psi_j^2 \quad (4.80)$$

kde váhový koeficient pravděpodobnostní funkce ψ je definován výrazem (4.81)

$$\psi_j = \begin{cases} 1 & \text{pro } j = 0 \\ \sum_{i=1}^j \phi_i^* \psi_{j-i} - \theta_j & \text{pro } j \geq 1 \end{cases} \quad (4.81)$$

kde $j = 1, 2, \dots, L$ a

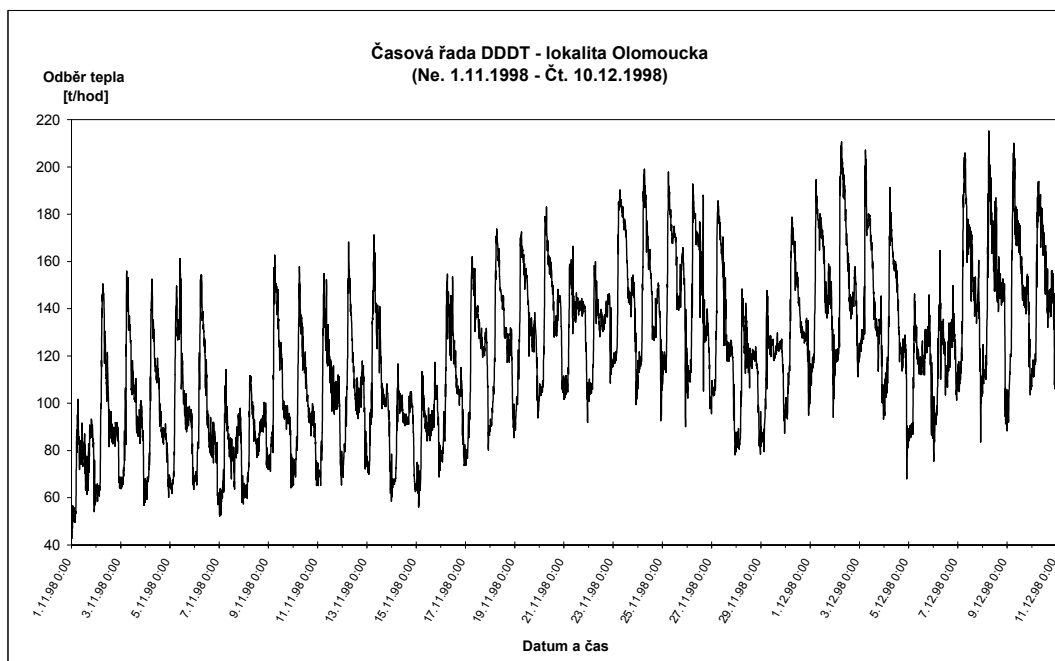
$$\begin{aligned} \phi_i^* &= 0 & \text{pro } i > p + sP + d + sD \\ \theta_j &= 0 & \text{pro } j > q + sQ \end{aligned} \tag{4.82}$$

Pokud při výpočtu nebudeme používat modelu klouzavého součtu (tzn. $Q=q=0$), je pro zjištění budoucích hodnot zbytečné provádět výpočet predikce, vztahující se k minulosti. Tzn., že nemusíme vyčíslovat vektor \vec{a} .

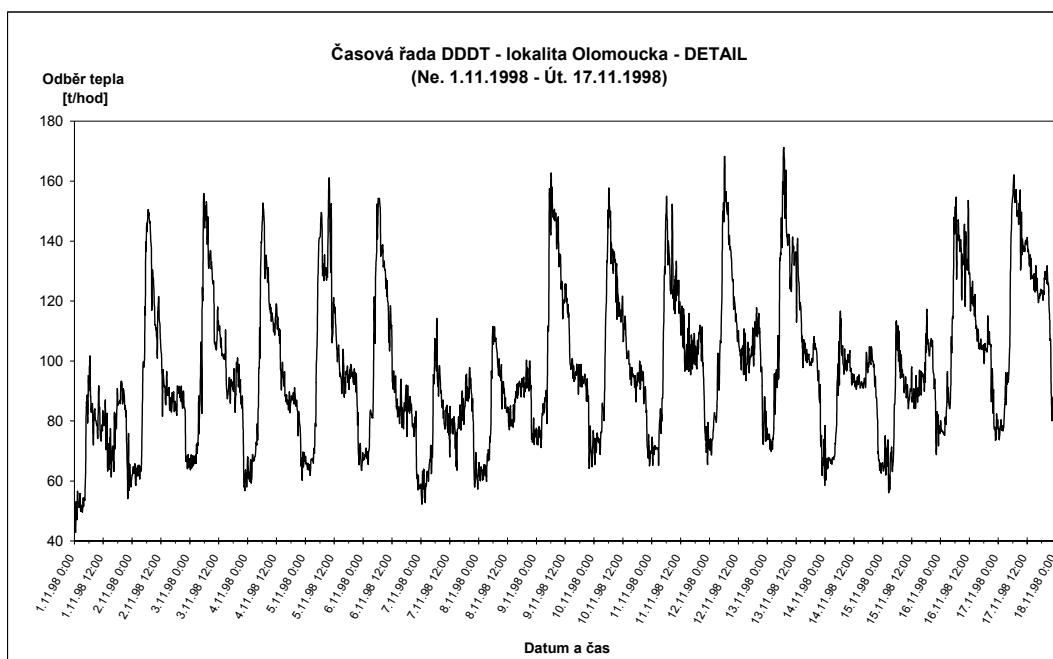
5 METODY A ZPŮSOB VÝPOČTU PREDIKCE ČASOVÉ ŘADY DDDT

5.1 Reálná časová řada DDDT

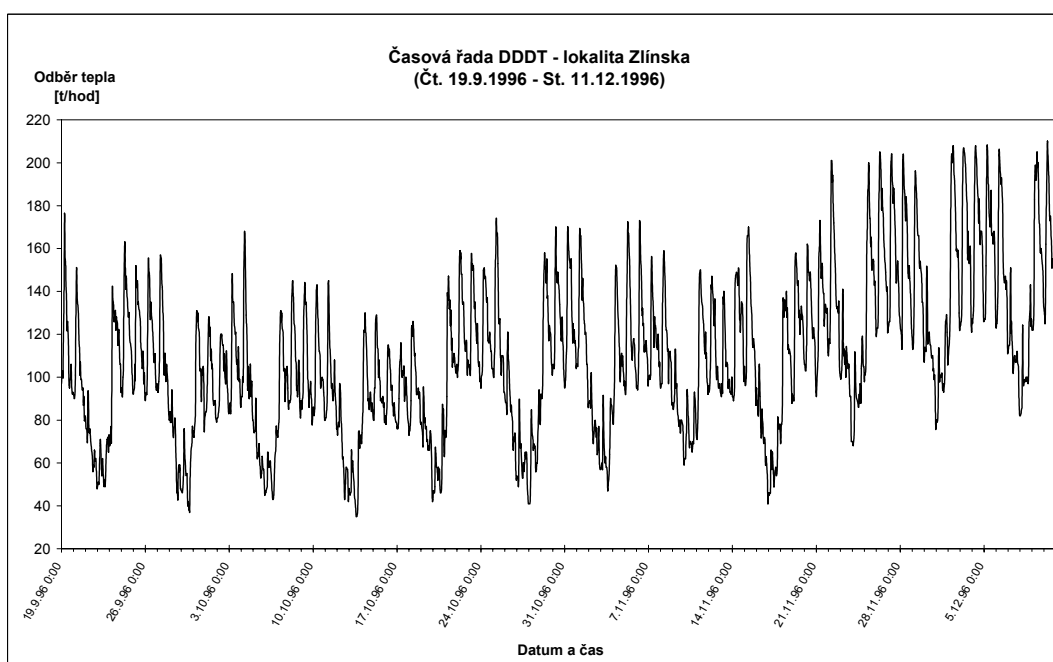
V úzké spolupráci se společností MST, a.s. – Teplárnou Olomouc a Teplárnou Otrokovice, a.s. byla získána konkrétní reálná data odběrů tepla (lokality Olomoucka a Zlínska). V lokalitě Olomoucka byla získána data z období mezi 1.11.1998 – 10.12.1998 a to s periodou 10 minut. Grafický průběh takto získané časové řady DDDT je zobrazen na Obr. 5.1 resp. Obr. 5.2. Ve Zlínské lokalitě byla shromážděna data z období 19.9.1996 – 11.12.1996 a to s periodou 1 hodina. Grafický průběh této časové řady je vidět na Obr. 5.3 resp. Obr. 5.4. Pro všechny hodnoty časové řady DDDT z Teplárny Otrokovice byly získány také odpovídající hodnoty venkovní teploty. U časové řady DDDT z Olomoucka byly hodnoty venkovní teploty sesbírány jen v období 1.11.1998 – 25.11.1998 a to s periodou 30 minut.



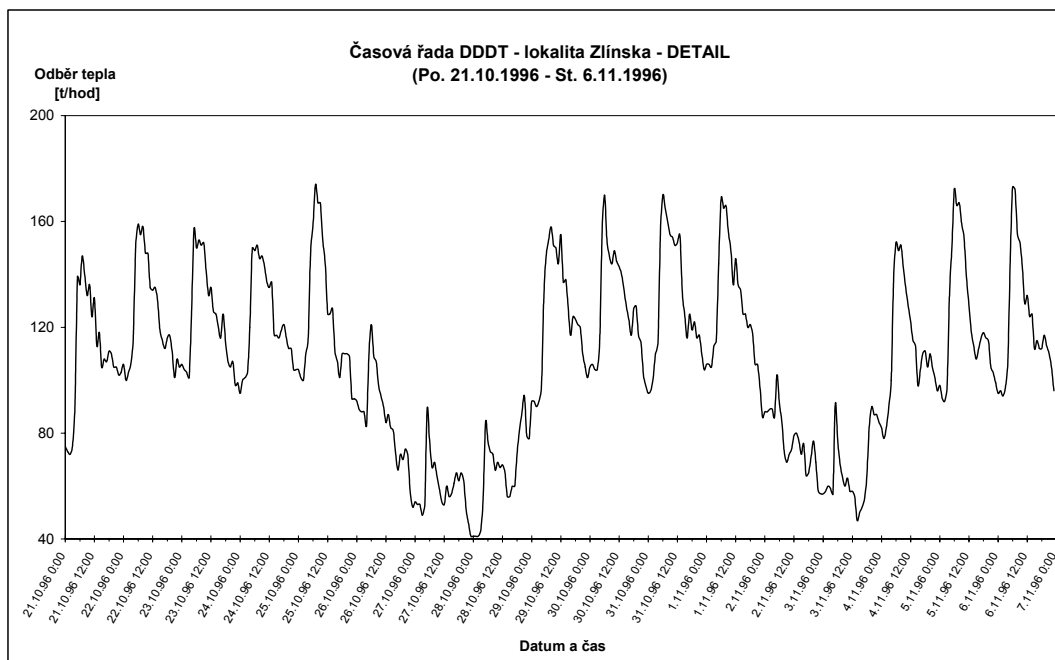
Obr. 5.1: Časová řada DDDT z lokality Olomoucka



Obr. 5.2: Časová řada DDDT z lokality Olomoucka – DETAIL



Obr. 5.3: Časová řada DDDT z lokality Zlínska



Obr. 5.4: Časová řada DDDT z lokality Zlínka - DETAIL

Jelikož průběh DDDT (viz předchozí obrázky) má tvar periodické časové řady s náhodným chováním, proto je vhodné využít při výpočtu poznatků z teorie pravděpodobnosti a matematické statistiky. Zkoumaný signál lze chápat jako realizaci náhodného procesu, který má stochastickou složku v superpozici s deterministickou složkou, danou fyzikálním základem procesu.

Praxe ukazuje, že většina časových řad může být rozdělena na několik složek [Cipra, 1986]. Jsou to:

- trend
- sezónní (periodická) složka
- cyklická složka
- reziduální (náhodná, zbytková, iregulární) složka

Rozklad časové řady do těchto složek se pak nazývá dekompozice časové řady.

Trend – odráží dlouhodobé změny v průměrném chování časové řady (např. dlouhodobý růst nebo dlouhodobý pokles).

Sezónní (periodická) složka – popisuje periodické změny v časové řadě, které se odehrávají během jednoho dne, týdne, roku a každý den, týden, rok se opakují.

Cyklická složka – je nejspornější složkou časové řady. Hovoří se spíše o fluktuacích okolo trendu, v nichž se střídá fáze růstu s fází poklesu. Délka jednotlivých cyklů je obvykle proměnlivá a stejně tak může být proměnlivá intenzita jednotlivých fází cyklického průběhu. Cyklická složka může být důsledkem evidentních vnějších vlivů, někdy je ale vytipování jejich příčin velmi obtížné.

Reziduální (náhodná, zbytková, iregulární) složka – zbývá v časové řadě po odstranění trendu a sezónní i cyklické složky. Je tvořena náhodnými pohyby (fluktuacemi) v průběhu časové řady, které nemají (rozpoznatelný) systematický charakter.

První tři složky představují deterministickou složku signálu. Čtvrtá složka představuje stochastickou složku signálu. V našem konkrétním případě (tj. u průběhu DDDT SCZT) se vyskytují tyto složky:

- sezónní - denní perioda (fluktuace odběru během dne),
- týdenní periodicita (pokles odběru v sobotu a neděli),
- trendová - plynulé přechody mezi ročními obdobími,
- náhodná - nepředvídané výkyvy v odběru tepla, meteorologické vlivy.

5.2 Výstavba modelu pro časovou řadu DDDT

Při analýze časových řad je nejdůležitější a zároveň nejobtížnější fází identifikace modelu časové řady. Tato kapitola nám odpoví na otázku, co je třeba udělat s časovou řadou před vlastní predikcí. Budeme se věnovat problému vyrovnání, transformace a filtrace časové řady. Dále se kapitola zabývá určením vhodného řádu diferencování a řádu autoregresního procesu resp. procesu klouzavých součtů. Závěr je věnován diagnostické kontrole zvoleného modelu a kritériím pro volbu modelu. Všechny tyto fáze výstavby modelu jsou pak prakticky realizována pro naši konkrétní časovou řadu DDDT.

5.2.1 Vyrovnání(vyhlazení) časové řady

Někdy je vhodné získanou časovou řadu před použitím upravit tak abychom eliminovali náhodné kolísání v krátkých časových intervalech. K tomuto účelu nám může napomoci například *metoda klouzavých průměrů*. Pojmem klouzavý průměr označujeme lineární kombinace členů původní řady. Vytváření takových konečných kombinací členů řady je ekvivalentní s vyrovnáváním krátkých úseků řady určitými matematickými křivkami. Při konstrukci klouzavých průměrů budeme pracovat s polynomickými křivkami. Postup je takový, že nejdříve vyrovnáme vhodným polynomem prvních $2m+1$ členů časové řady a použijeme hodnotu tohoto polynomu v bodě $t=m+1$ (tj. ve středu uvažovaného úseku) jako vyrovnanou hodnotu \hat{z}_{m+1} dané časové řady v tomto bodě. Pak pro získání vyrovnané hodnoty v bodě $t=m+2$ provedeme totéž s hodnotami $z_2, z_3, \dots, z_{2m+2}$ atd. Obecně můžeme vyrovnávat úsek o délce $2m+1$ polynomem r -tého řádu a tak obdržet *klouzavé průměry délky $2m+1$ a řádu r* . Vyrovnaná hodnota \hat{z}_t v bodě t je pak dána lineární kombinací hodnot z_{t-m}, \dots, z_{t+m} (5.1) s pevně určenými koeficienty $\beta_1, \dots, \beta_{2m+1}$, které se nazývají *váhy klouzavého průměru*. Tyto váhy klouzavých průměrů jsou symetrické kolem prostřední hodnoty a jejich součet je roven jedné. Váhy 2. až 5. řádu pro různé délky jsou přehledně uvedeny v tabulce 2.

$$\hat{z}_t = \beta_1 z_{t-m} + \beta_2 z_{t-m+1} + \dots + \beta_{2m+1} z_{t+m} \quad (5.1)$$

Tabulka 2: Váhy klouzavých průměrů

Řád Délka	2. a 3.	4. a 5.
3	(0, 1, 0)	(0, 1, 0)
5	$\frac{1}{35}(-3, 12, 17, 12, -3)$	(0, 0, 1, 0, 0)
7	$\frac{1}{21}(-2, 3, 6, 7, 6, 3, -2)$	$\frac{1}{231}(5, -30, 75, 131, 75, -30, 5)$
9	$\frac{1}{231}(-21, 14, 39, 54, 59, 54, \dots)$	$\frac{1}{429}(15, -55, 30, 135, 179, 135, \dots)$
11	$\frac{1}{429}(-36, 9, 44, 69, 84, 89, 84, \dots)$	$\frac{1}{429}(18, -45, -10, 60, 120, 143, 120, \dots)$
13	$\frac{1}{143}(-11, 0, 9, 16, 21, 24, 25, 24, \dots)$	$\frac{1}{2431}(110, -198, -135, 110, 390, 600, 677, \dots)$

Poznamenejme, že vyrovnaním řady pomocí popsané techniky klouzavých průměrů získáme vyrovnané hodnoty pouze pro $t=m+1, \dots, n-m$ (tj. m hodnot na začátku a m hodnot na konci uvažované řady z_1, \dots, z_n zbývá nevyrovnáno). K vyrovnaní těchto hodnot lze použít tzv. *klouzavé průměry počáteční resp. koncové* (viz. [Cipra, 1986]).


Pro metodu klouzavých průměrů zůstává otázkou, jaký řád a délku klouzavého průměru pro předloženou časovou řadu zvolit. Obvykle se rozhodujeme na základě subjektivního posouzení charakteru dat s tím, že preferujeme jednoduché průměry co nejnižšího řádu a délku volíme podle požadovaného stupně vyhlazení řady (čím větší je délka klouzavého průměru, tím větší je vyhlazení časové řady). O řádu klouzavých průměrů lze rozhodnout také na základě objektivního kritéria, které spočívá v postupném diferencování předložené řady. Jde vlastně o výpočet hodnot V_k podle vzorce (5.2)

$$V_k = \frac{\sum_{t=k+1}^n (\nabla^k z_t)^2}{\binom{2k}{k}(n-k)} \quad (5.2)$$

Tato hodnota pak reprezentuje pro $k \geq (r+1)$ odhad hodnoty rozptylu bílého šumu. Prakticky počítáme postupně hodnoty V_1, V_2, \dots , dokud nezaznamenáme, že tyto hodnoty začínají konvergovat k nějaké konstantě. Jestliže hodnoty V_{r+1}, V_{r+2}, \dots , jsou již blízké této konstantě, pak popsané kritérium hovoří ve prospěch klouzavých průměrů řádu r .

Vyhlazení časové řady DDDT

V této části budeme aplikovat vyhlazení pomocí klouzavých průměrů na časovou řadu DDDT. Uvažujme tedy část časové řady DDDT, která je graficky zobrazena na Obr. 5.5. Pro tuto řadu postupně vypočteme hodnoty V_k uvedené v tabulce 3. Na základě těchto hodnot můžeme rozhodnout, že postačujícími budou klouzavé průměry 3. řádu neboť dáváme přednost pokud možno klouzavým průměrům nižších řádů a hodnoty V_k jsou pro $k > 3$ ve srovnání s hodnotami V_1, V_2, V_3 již značně stabilizované.



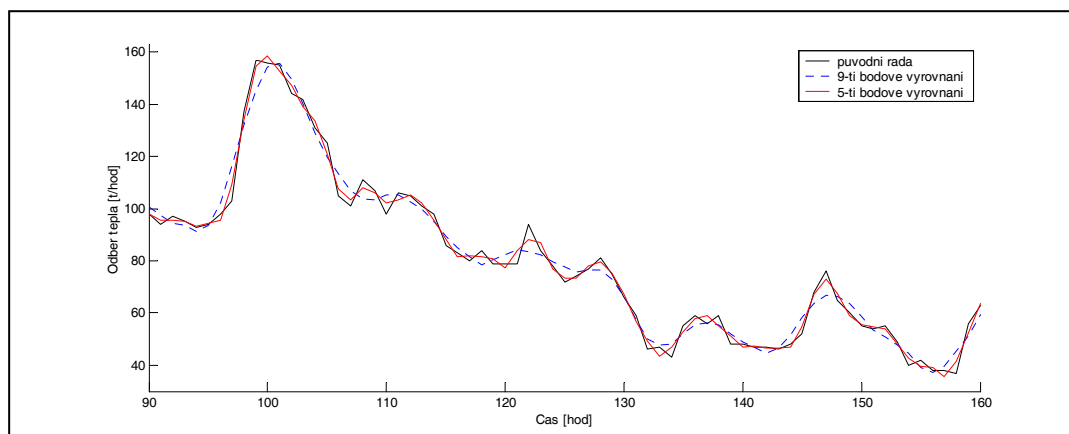
Obr. 5.5: Část časové řady DDDT určená k vyhlazení pomocí klouzavých průměrů

Tabulka 3: Hodnoty V_k pro uvažovanou časovou řadu DDDT – určení řádu klouzavých průměrů

k	1	2	3	4	5	6	7	8	9	10
V_k	50,994	28,248	24,698	23,529	22,980	22,599	22,085	21,358	20,576	19,933

Provedme tedy vlastní vyhlazení uvažované časové řady pomocí klouzavých průměrů 3. řádu. Do Obr. 5.6 jsou zaneseny průběhy klouzavých průměrů tohoto řádu pro délky 5 a 9 (pro názornost je zobrazena jen část uvažované časové řady). Pro výpočet byly použity příslušné váhy z tabulky 2. Z obrázku je jasné, že klouzavé průměry délky 5 sledují poměrně těsně skutečný průběh časové řady a vyhlazení v této podobě je tedy pro náš účel použití výhodnější než klouzavé průměry délky 9, které mohou někdy eliminovat i některé periodické fluktuace, což je v našem případě nevhodné.

Závěrem je nutné podotknout, že uvažovaná časová řada DDDT byla naměřena s periodou 1 hodina, což znamená, že při délce klouzavých průměrů 5 vyrovnáváme úsek v délce 5 hodin. Jinak tomu bude u časové řady, kterou naměříme s jinou periodou.



Obr. 5.6: Průběhy klouzavých průměrů 3. řádu pro délky 5 a 9

5.2.2 Transformace časové řady

Při analýze časových řad se můžeme setkat s případy, kdy je zjevné, že generující procesy jsou nestacionární z hlediska rozptylu jednotlivých jejich náhodných veličin. Stacionarizaci přitom nelze dosáhnout diferencováním. V těchto případech je třeba počítat s tím, že generující procesy mají nelineární charakter a není tedy možné pracovat s lineárními modely typu ARIMA. Problém takovéto nelinearity, který vede k nestacionaritě z hlediska rozptylu lze řešit pomocí jistých linearizujících transformací. Obecně řečeno, účelem takovéto transformace časové řady je linearizovat řadu tak, aby ji bylo možné popsat modelem ARIMA nebo jeho speciálními případy AR, MA nebo ARMA. V této části se budeme zabývat otázkou výběru vhodné linearizující transformace pro analyzovanou časovou řadu. Velmi obecně k problému přistoupili Box a Cox [Box & Cox, 1964], kteří navrhli transformaci ve tvaru:

$$\begin{aligned}
 z_t^{(\lambda)} &= \frac{z_t^\lambda - 1}{\lambda} & \text{pro } \lambda \neq 0 \\
 z_t^{(\lambda)} &= \ln(z_t) & \text{pro } \lambda = 0
 \end{aligned}
 \tag{5.3}$$

Kde $z_t^{(\lambda)}$ označuje transformovanou řadu. Jedná se tedy o nelineární transformaci, která je závislá na neznámém parametru λ , který je označován jako *transformační parametr*. Tento parametr je možné odhadnout metodou maximální věrohodnosti. Odhad parametru λ je výpočetně náročná operace a navíc není tato náročnost vyvážena jejím

skutečným efektem. Proto se v praxi dává přednost jednodušším metodám hledání vhodné transformace časových řad. Praktičtější přístup navrhuje mocninovou transformaci ve tvaru:

$$\begin{aligned} z_t^{(\lambda)} &= z_t^\lambda && \text{pro } \lambda \neq 0 \\ z_t^{(\lambda)} &= \ln(z_t) && \text{pro } \lambda = 0 \end{aligned} \quad (5.4)$$

Přítom o hodnotě λ lze rozhodnout graficky: daná řada se rozdělí na krátké úseky, které obsahují 4-12 pozorování; v každém úseku se zjistí aritmetický průměr (označme jej m) odpovídajících pozorování a jejich směrodatná odchylka (označme ji S); pak se vytvoří bodový diagram, do kterého se zanesou body (m, S) . Pokud tyto body leží přibližně na přímce s nulovou směrnici není třeba dále časovou řadu transformovat. Jestliže však body leží přibližně na rostoucí přímce, je nutné linearizovat řadu logaritmováním. Prakticky se tato činnost provede tak, že se nejprve řada transformuje a potom se pomocí grafu posuzuje zda se variabilita řady mění s její úrovní. Přítom se nejčastěji používají hodnoty transformačního parametru uvedené v tabulce 4.

Tabulka 4: Hodnoty transformačního parametru λ s odpovídajícími transformacemi

λ	-1	-0,5	0	0,5	1
transformace	$\frac{1}{z_t}$	$\frac{1}{\sqrt{z_t}}$	$\ln(z_t)$	$\sqrt{z_t}$	z_t bez transformace

Hodnota λ se sice pomocí této metody určí jen velmi přibližně, ale pro praktické účely je tento hrubý odhad postačující.

Určení transformace pro časovou řadu DDDT

Úkolem nyní je zvolit vhodnou transformaci pro naši konkrétní časovou řadu DDDT. Podíváme-li se na grafické průběhy časové řady DDDT, které jsou zobrazeny na Obr. 5.1 nebo na Obr. 5.3 je zřetelně vidět, že její variabilita zůstává přibližně konstantní, pokud si ovšem odmyslíme týdenní periodicitu (tj. pokles odběru tepla v sobotu a neděli). To tedy znamená, že v našem konkrétním případě není třeba časovou řadu DDDT nějakým způsobem transformovat.

5.2.3 Určení řádu diferencování

Při výstavbě modelů třídy ARIMA je velmi důležité určení *řádu diferencování* d . Účelem případného diferencování řady je odstranění nestacionarity způsobené přítomností trendu. Pro časové řady z praxe se setkáme s integrovanými časovými řadami maximálně řádu 2. To znamená, že časové řady se stacionarizují většinou prostřednictvím první či druhé diference. V této souvislosti se nabízí několik možností, jak určit řád diferencování.

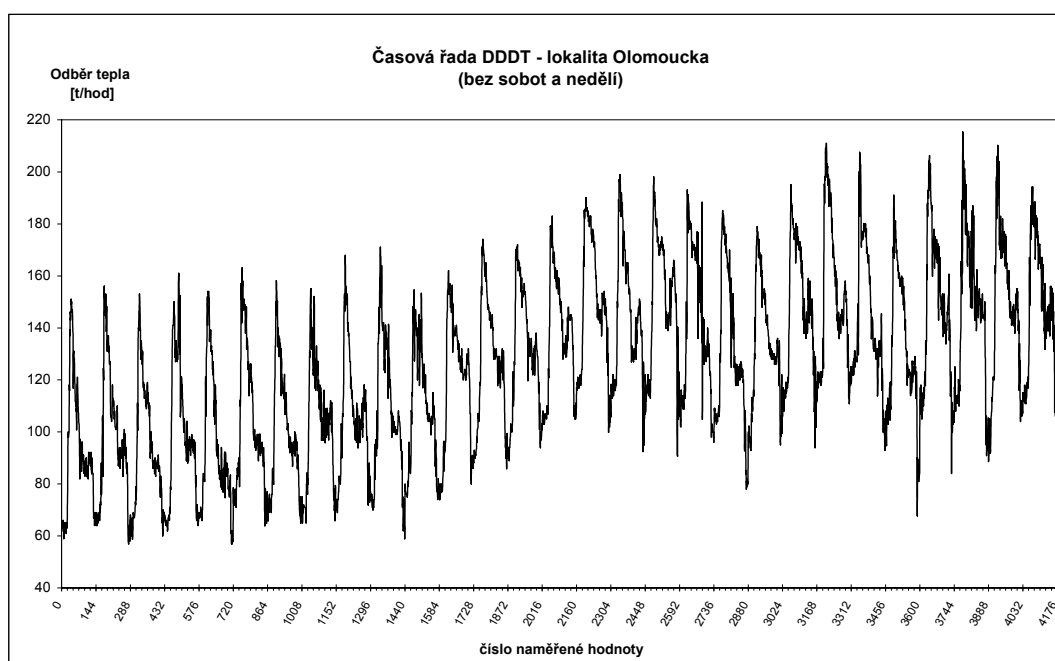
1. Použije se grafický záznam řady. Pokud máme pochybnosti o stacionaritě této řady, zakreslí se dále řada prvních nebo dokonce druhých diferencí a opticky se posoudí stacionarita těchto diferencovaných řad.
2. Jednou z objektivnějších metod je studium odhadnuté autokorelační funkce r_k dané časové řady. Jestliže hodnoty r_k klesají pomalu (přibližně lineárním a nikoli geometrickým tempem), pak je to příznakem toho, že alespoň jeden kořen autoregresního operátoru je velice blízký jedné a je tedy zapotřebí provést diferencování.
3. Anderson ve své práci [Anderson, 1976] dává přednost metodě, při níž se posuzuje velikost odhadnutého rozptylu σ_z^2 dané řady a rozptylů $\sigma_{\nabla z}^2, \sigma_{\nabla^2 z}^2, \dots$ jejich diferencí. Za d se pak zvolí ta hodnota, která dává nejmenší odhadnutý rozptyl.

Vzhledem k tomu, že hodně časových řad z praxe vykazuje také sezónnost, je nutné určit tzv. *řád sezónního diferencování* – D . Účelem takového diferencování je pak odstranění nestacionarity způsobené sezónním chováním. Diferencování dané operátorem ∇ odlišme od *sezónního diferencování* s operátorem ∇_s označením *běžné diferencování*. V sezónních modelech se málokdy provádí sezónní diferencování většího řádu než 1, takže v podstatě musíme rozhodnout mezi případy $D=0$ nebo $D=1$. To se většinou děje na základě studia odhadnuté autokorelační funkce r_k , přičemž se doporučuje prozkoumat asi $4*s$ prvních hodnot této funkce. Jestliže funkce r_k má v bodech k , které jsou násobky s lokální maxima, pak bez ohledu na její průběh mezi těmito časovými body je nutné


položít řád sezónního diferencování $D=1$. Tzn. je nutné časovou řadu sezónně diferencovat ve tvaru $\nabla_s z_t$.

Určení řádu diferencování pro časovou řadu DDDT

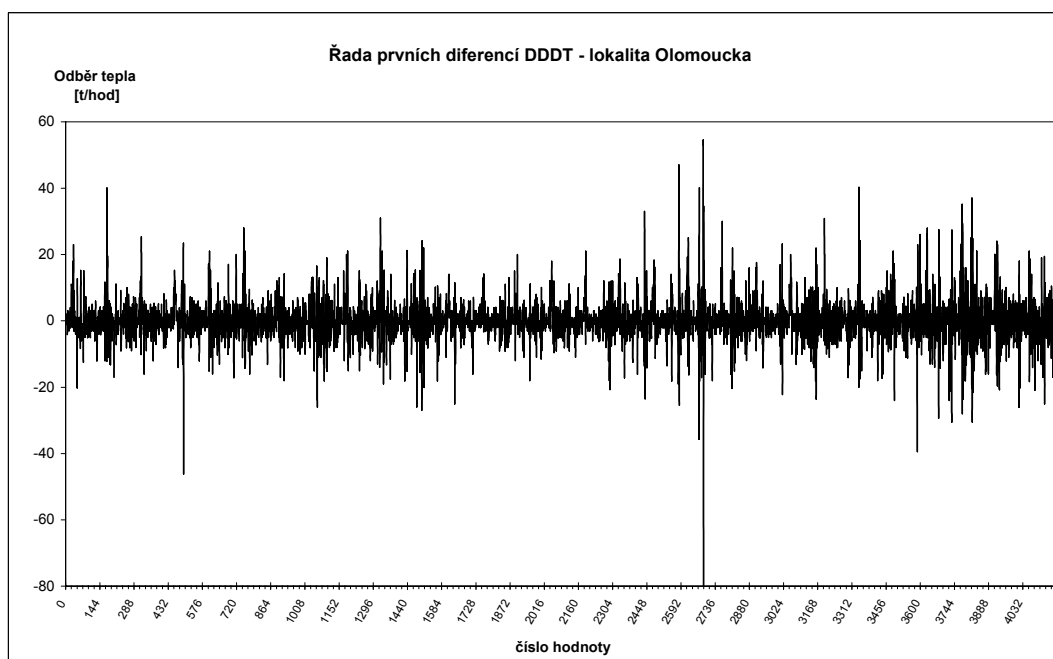
Uvažujme nyní znovu naši konkrétní časovou řadu DDDT a určíme pro ni vhodný řád běžného diferencování a také řád sezónního diferencování. Protože model Box-Jenkinse dokáže modelovat pouze časové řady s jednou periodou, budeme při hledání řádu diferencování používat hodnoty bez sobot a nedělí respektive bez svátků. Z grafických průběhů nově vzniklých časových řad DDDT na Obr. 5.7 resp. Obr. 5.8 je vidět, že řady vykazují zjevnou nestacionaritu. Je tedy nutné tyto řady diferencovat. Řady prvních diferencí jsou graficky zobrazeny na Obr. 5.9 resp. Obr. 5.10.



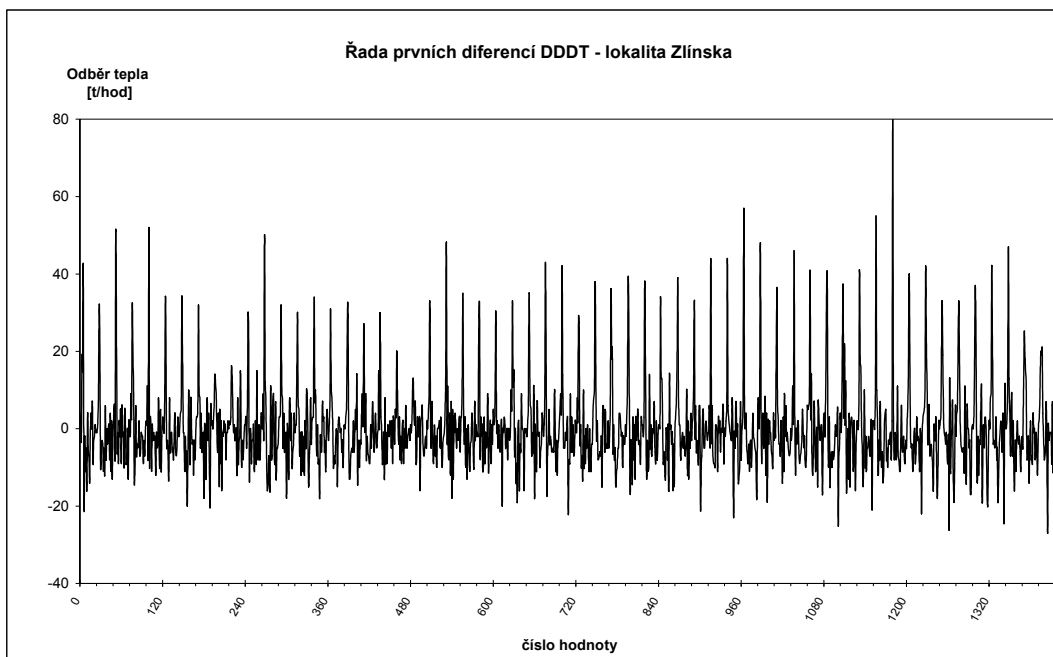
Obr. 5.7: Časová řada DDDT – lokalita Olomoucka (bez sobot a nedělí)



Obr. 5.8: Časová řada DDDT – lokalita Zlínska (bez sobot, nedělí a svátku 28.10.)



Obr. 5.9: Řada prvních diferencí časové řady DDDT – lokalita Olomoucka



Obr. 5.10: Řada prvních diferencí časové řady DDDT – lokalita Zlínka

Z průběhů těchto řad se zdá, že je lze již považovat za stacionární. Přesvědčíme se o tom zkoumáním průběhu odhadnuté autokorelační funkce. Hodnoty odhadnutých autokorelačních funkcí r_k původních nediferencovaných časových řad jsou zachyceny v korelogramech na Obr. 5.11 resp. Obr. 5.12, odkud je jasně vidět, že tato funkce opravdu klesá velmi pomalu a v žádném případě geometrickým tempem. Průběhy odhadnutých autokorelačních funkcí řad prvních diferencí lze najít na Obr. 5.13 resp. Obr. 5.14. Tyto průběhy již hovoří ve prospěch stacionarity diferencovaných řad z hlediska trendu. Proto lze položit za řád běžného diferencování hodnotu $d = 1$.

Pro jistotu porovnejme ještě odhadnuté rozptyly řad $z_t, \nabla z_t$ a $\nabla^2 z_t$, jejichž hodnoty jsou:

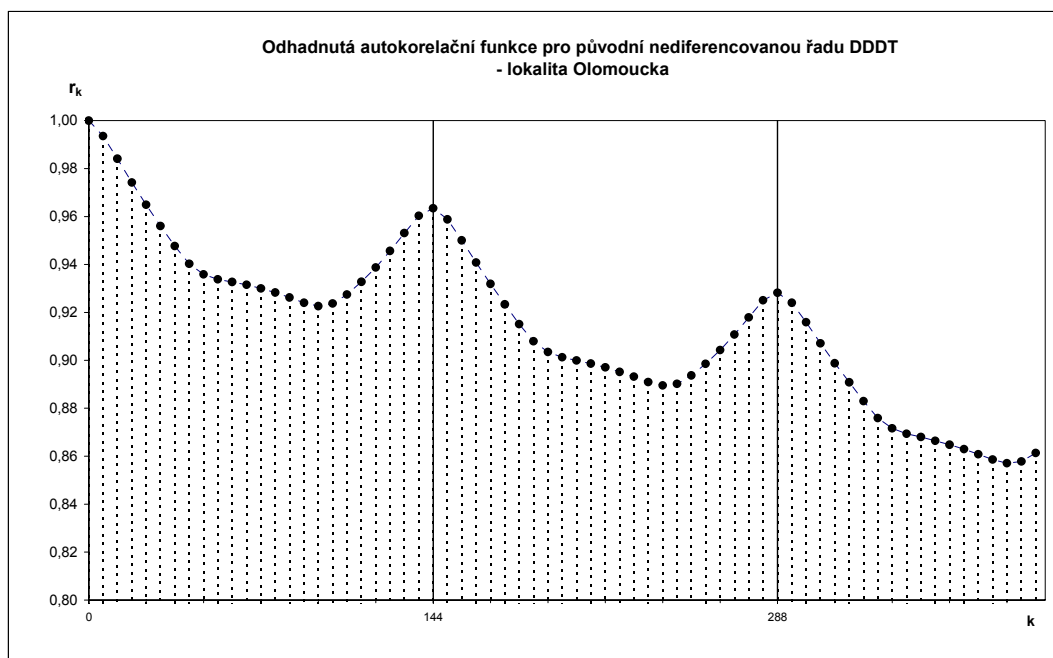
$$\hat{\sigma}_z^2 = 1082,083, \quad \hat{\sigma}_{\nabla z}^2 = 43,473, \quad \hat{\sigma}_{\nabla^2 z}^2 = 106,851 \quad (5.5)$$

respektive


$$\hat{\sigma}_z^2 = 967,685, \quad \hat{\sigma}_{\nabla z}^2 = 119,861, \quad \hat{\sigma}_{\nabla^2 z}^2 = 168,234 \quad (5.6)$$

Je tedy vidět, že rozptyl řady po prvním diferencování podstatně klesne, ale při dalším diferencování již zase začíná narůstat, takže i při tomto postupu padne volba na hodnotu řádu běžného diferencování $d = 1$.

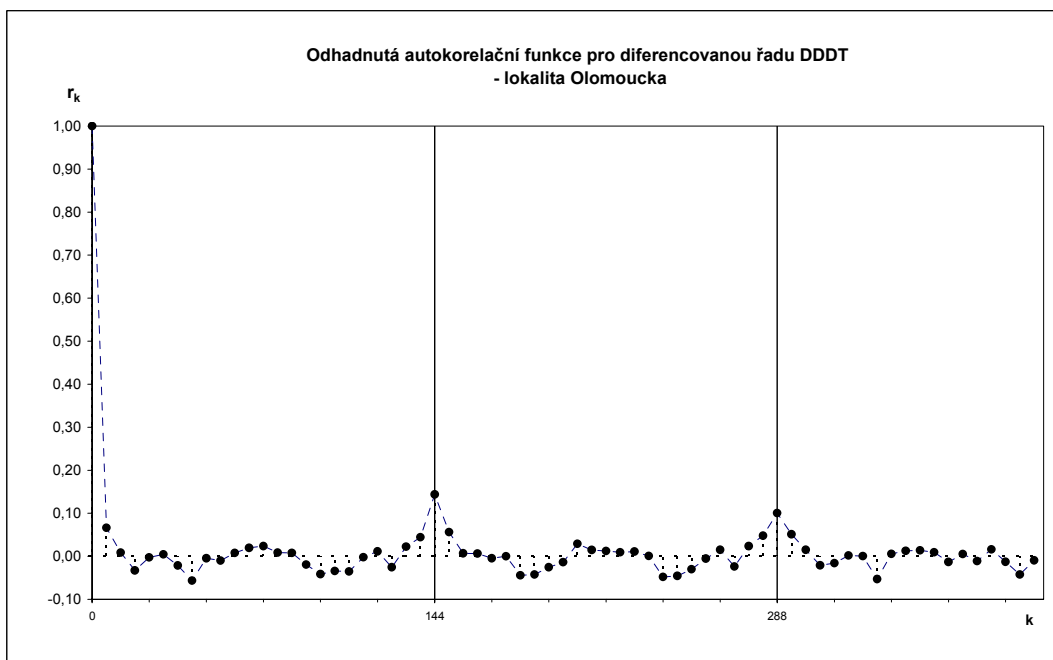
Jelikož naše konkrétní časová řada DDDT vykazuje zjevný sezónní charakter je třeba provést také analýzu na řád sezónního diferencování. Sezónní charakter je jasně vidět také z průběhů odhadnutých autokorelačních funkcí (viz. Obr. 5.11 resp. Obr. 5.12). Funkce r_k nabývá lokálního maxima v bodech 144, 288, ... resp. v bodech 24, 48, To představuje v prvním případě (lokalita Olomoucka) při periodě vzorkování 10 minut sezónní periodu 24 hodin. Ve druhém případě (lokalita Zlínska) dostáváme při periodě vzorkování 1 hodina taktéž sezónní periodu 24 hodin.



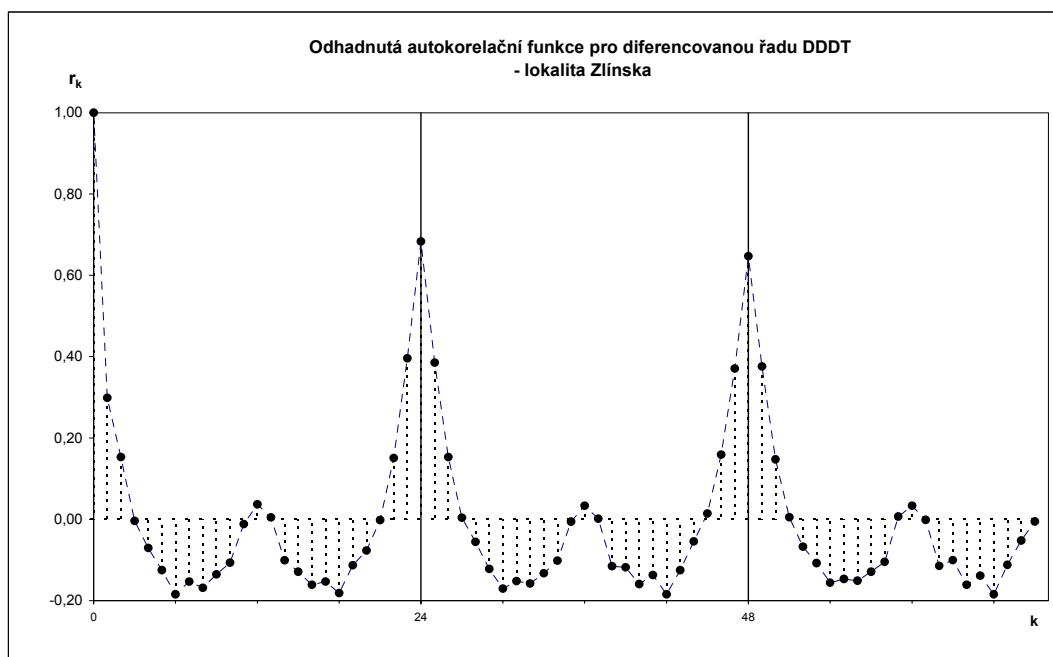
Obr. 5.11: Odhadnutá autokorelační funkce pro původní nediferencovanou časovou řadu DDDT – lokalita Olomoucka



Obr. 5.12: Odhadnutá autokorelační funkce pro původní nediferencovanou časovou řadu DDDT – lokalita Zlínka



Obr. 5.13: Odhadnutá autokorelační funkce pro diferencovanou časovou řadu DDDT – lokalita Olomoucka



Obr. 5.14: Odhadnutá autokorelační funkce pro diferencovanou časovou řadu DDDT – lokalita Zlínka

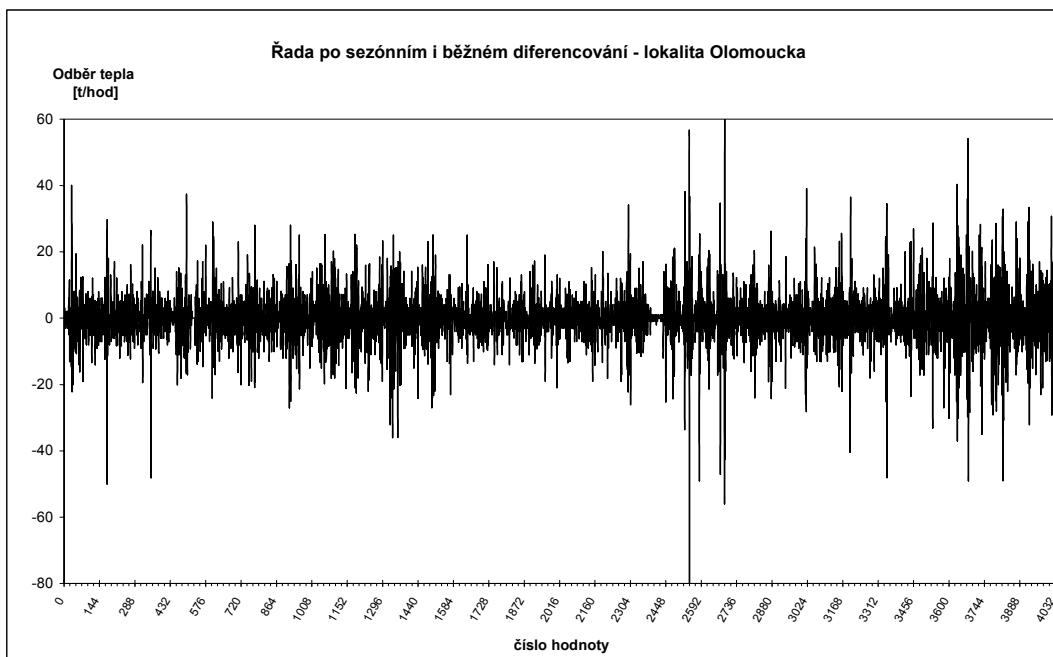
Závěrem lze tedy říci, že pro naši uvažovanou časovou řadu DDDT je třeba provést jak běžné tak i sezónní diferencování a to ve tvaru:

$$\nabla\nabla_{144}z_t = z_t - z_{t-1} - z_{t-144} + z_{t-145} \quad (5.7)$$

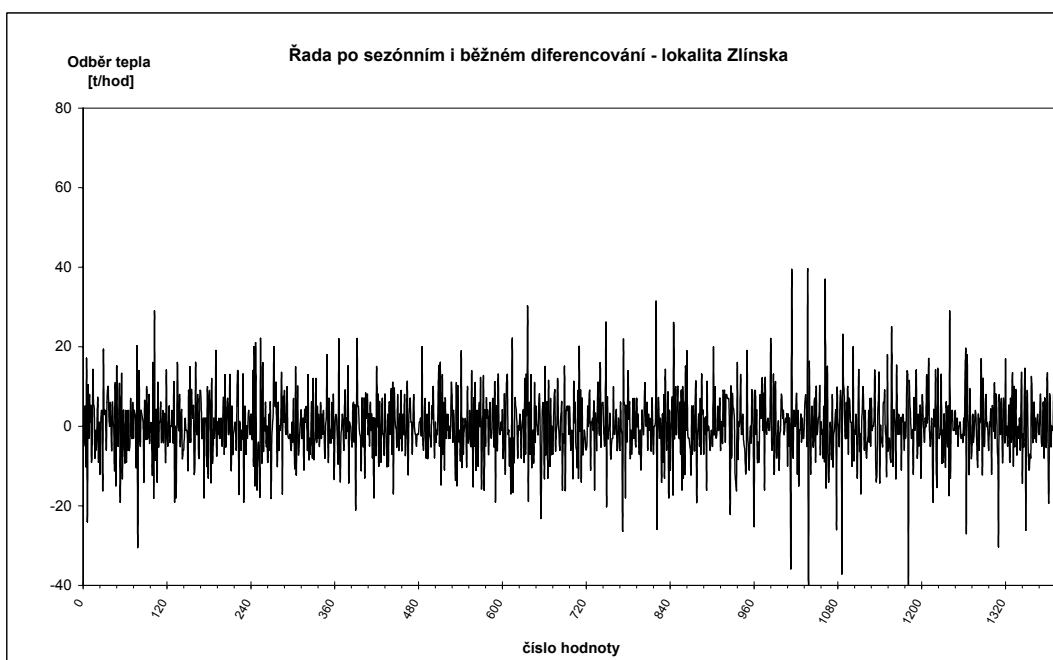
Respektive

$$\nabla\nabla_{24}z_t = z_t - z_{t-1} - z_{t-24} + z_{t-25} \quad (5.8)$$

Průběhy takto diferencovaných časových řad jsou zobrazeny na Obr. 5.15 respektive na Obr. 5.16.



Obr. 5.15: Řada po sezónním i běžném diferencování – lokalita Olomoucka



Obr. 5.16: Řada po sezónním i běžném diferencování – lokalita Zlínka

Někdy se řady diferencování d a D také určují tak, že se hledá minimální hodnota mezi odhadnutými rozptyly $\hat{\sigma}_z^2, \hat{\sigma}_{\nabla z}^2, \hat{\sigma}_{\nabla^2 z}^2, \hat{\sigma}_{\nabla^3 z}^2, \hat{\sigma}_{\nabla^4 z}^2$ dané řady a jejich diferencí. Pro naše uvažované řady byly hodnoty těchto rozptylů vypočteny takto:

$$\begin{aligned} \hat{\sigma}_z^2 &= 1082,083, & \hat{\sigma}_{\nabla z}^2 &= 43,473, & \hat{\sigma}_{\nabla^2 z}^2 &= 106,851 \\ \hat{\sigma}_{\nabla^{144} z}^2 &= 134,340, & \hat{\sigma}_{\nabla^2 \nabla^{144} z}^2 &= 73,765 \end{aligned} \quad (5.9)$$

respektive

$$\begin{aligned} \hat{\sigma}_z^2 &= 967,685, & \hat{\sigma}_{\nabla z}^2 &= 119,861, & \hat{\sigma}_{\nabla^2 z}^2 &= 168,234 \\ \hat{\sigma}_{\nabla^{144} z}^2 &= 150,522, & \hat{\sigma}_{\nabla^2 \nabla^{144} z}^2 &= 72,708 \end{aligned} \quad (5.10)$$

I z těchto výsledků se dá usoudit, že diferencování ve tvaru $\nabla \nabla_s z_t$ je oprávněné. Jen v prvním případě je hodnota rozptylu $\hat{\sigma}_{\nabla z}^2$ nižší než hodnota rozptylu $\hat{\sigma}_{\nabla^2 z}^2$ při dvojnásobném diferencování. Je to dáno hodně malou vzorkovací periodou dané řady (10 minut), kdy rozdíly mezi hodnotami jsou nízké.

5.2.4 Určení řádu autoregresního polynomu a řádu polynomu klouzavých součtů

Po diferencování časové řady je třeba rozhodnout, jaký typ modelu vybrat (tj. zda AR, MA nebo ARMA) a explicitně určit řád modelu. Výsledkem této identifikační fáze je tedy stanovení řádu autoregresního polynomu $\phi_p(B)$, tj. číslo p , a řád polynomu klouzavých průměrů $\theta_q(B)$, tj. číslo q . Tradiční metoda spočívá v hledání podobností ve tvaru odhadnuté autokorelační funkce (ACF) a odhadnuté parciální autokorelační funkce (PACF) a jejich teoretických protějšků známých modelů. Řád p a q není obvykle příliš vysoký, proto nám stačí získat obvykle jen prvních asi 20 hodnot funkcí ACF a PACF. Úkolem je především určit případný identifikační bod. Tabulka 5 obsahuje přehled tvarů ACF a PACF stacionárních modelů typu ARMA.

Tabulka 5: Vlastnosti ACF a PACF pro různé modely typu ARMA

Model	Tvar ACF	Tvar PACF
(1, 0)	Exponenciální nebo oscilační pokles	$\rho_{kk} = 0$, pro $k > 1$
(2, 0)	Exponenciální nebo exponenciálně sinusoidní pokles	$\rho_{kk} = 0$, pro $k > 2$
(p , 0)	Exponenciální a/nebo exponenciálně sinusoidní pokles	$\rho_{kk} = 0$, pro $k > p$
(0, 1)	$\rho_k = 0$, pro $k > 1$	Exponenciální nebo oscilační pokles
(0, 2)	$\rho_k = 0$, pro $k > 2$	Exponenciální nebo exponenciálně sinusoidní pokles
(0, q)	$\rho_k = 0$, pro $k > q$	Exponenciální a/nebo exponenciálně sinusoidní pokles
(1, 1)	Od zpoždění 1 exponenciální nebo oscilační pokles	Od zpoždění 1 exponenciální nebo oscilační pokles
(p , q)	Od zpoždění ($q-p$) exponenciální nebo exponenciálně sinusoidní pokles	Od zpoždění ($p-q$) exponenciální nebo exponenciálně sinusoidní pokles

Někdy je velmi obtížné určit typ modelu na základě ACF a PACF. V situacích velké nejistoty je vhodné soustředit se především na základní rysy odhadnuté ACF a PACF, detaily v jejich vývoji je třeba pominout. I přesto nemusí být závěr tohoto identifikačního postupu jednoznačný a je třeba se rozhodnout mezi více alternativami. Navíc tento postup vyžaduje značnou dávku zkušeností s výstavbou modelů a je často zatížen některými subjektivními rysy. Není proto divu, že jsou požadovány objektivní identifikační procedury, při nichž by celá tíha rozhodnutí mohla být přenechána počítači a uživatel by případně toto rozhodnutí jen upravil na základě svých znalostí o povaze problému. V současnosti existuje několik takových objektivních metod, které pomáhají při identifikaci modelu. Podrobně jsou popsány v kapitole 5.2.6.

5.2.5 Diagnostická kontrola modelu

Po volbě řádu diferencování, autoregresní části a částí klouzavých průměrů a po odhadnutí parametrů modelu je třeba provést ověřování výsledného odhadnutého modelu.

Toto ověřování má potvrdit nebo zamítnout adekvátnost modelu. Metod existuje celá řada a každá z nich posuzuje adekvátnost modelu z různých hledisek a s různou účinností. Proto se doporučuje použít více takových metod současně.

Kontrola rozptylu nesystematické složky

Nejjednodušším prostředkem k posouzení adekvátnosti modelu je prozkoumat rozptyl nesystematické složky – odhadnutých reziduí \hat{a} . To znamená, že z grafu reziduí posuzujeme proměnlivost rozptylu nebo-li tzv. heteroskedasticidu. V praxi se velmi často používá test pro posouzení, zda nesystematická složka modelu vykazuje tzv. ARCH(q) (AutoRegressive Conditional Heteroscedasticity) efekt (viz. [Cromwell a kol., 1994]).

Autokorelace nesystematické složky

Dále můžeme posuzovat autokorelaci nesystematické složky (rezidua) modelu. To lze provést pomocí odhadnuté ACF. Není-li nesystematická složka autokorelována, měly by hodnoty této funkce ležet uvnitř intervalu $\left\langle -2\sqrt{\frac{1}{n}}, 2\sqrt{\frac{1}{n}} \right\rangle$ (95% interval spolehlivosti).

Portmanteau test

Toto označení se vžilo pro test, v němž se adekvátnost modelu testuje pomocí souhrnného korelačního chování odhadnutých reziduí \hat{a} . Tato metoda neposkytuje tak přesné výsledky ale je hodně oblíbená zejména pro její výpočetní jednoduchost. Pracujeme zde s tzv. *portmanteau statistikou*, která je dána vztahem

$$Q = n \sum_{k=1}^K r_k^2(\hat{a}) \quad (5.11)$$

Kde K je vhodně vybrané číslo (doporučuje se obvykle volit $K = \sqrt{n}$, kde n je délka analyzované řady. Jestliže tedy ověřujeme pomocí Q adekvátnost modelu $ARMA(p, q)$, pak statistika Q má při větším n přibližně rozdělení χ_{K-p-q}^2 (tj. rozdělení chí-kvadrát s $K-p-q$ stupni volnosti). Pokud Q překročí příslušnou kritickou hodnotu $\chi_{K-p-q}^2(\nu)$ odpovídající hladině významnosti ν (tyto hodnoty lze nalézt ve statistických tabulkách), pak na dané hladině významnosti zamítneme ověřovaný model jako nevhodný.

V poslední době byly navrženy i jiné testové charakteristiky, které jsou podobné charakteristice Q a které se jeví jako efektivnější. Doporučovaná je například statistika ve tvaru:

$$Q^* = n(n+2) \sum_{k=1}^K \frac{r_k^2(\hat{a})}{n-k} \quad (5.12)$$

Tato statistika se nazývá *modifikovaná portmanteau statistika*.

5.2.6 Kriteria pro volbu modelu

Jak již bylo zmíněno výše, při analýze konkrétní časové řady můžeme dojít k závěru, že není možné jednoznačně rozhodnout o vhodném typu modelu. Proto byly hledány objektivní metody pro stanovení řádu modelu. Metody založené na statistickém testování hypotéz se přitom pro tento účel příliš neosvědčily, protože nejsou vhodné pro začlenění do počítačových programů. Zato se začaly běžně používat tzv. dodatečná kritéria, při nichž se přímo získá bodový odhad řádu modelu. Tato kritéria jsou založena na porovnání reziduí jednotlivých modelů prostřednictvím sumárních statistik.

Akaikeho kritérium AIC (Akaike Information Criterion)

Toto kritérium, které Akaike odvodil na základě jistých principů teorie informace má tvar:

$$AIC(p, q) = n \cdot \ln \hat{\sigma}_a^2 + 2(p + q) \quad (5.13)$$

Kde p, q jsou počty parametrů v modelu ARMA(p, q) a $\hat{\sigma}_a^2$ je odhad rozptylu reziduí tohoto modelu. Hodnota n je počet pozorování, který je roven počtu reziduí získaných na základě daného modelu. Vybere se pak takový model, který vede k minimální hodnotě tohoto kritéria. Vzhledem ke svému jednoduchému tvaru patří kritérium AIC k nejpoužívanějším.

Bayesovské kritérium BIC (Bayesian Information Criterion)

Při praktických aplikacích a na základě simulací však bylo zjištěno, že kritérium AIC vede k nadhodnocování řádu autoregrese. Proto Akaike rozšířil kritérium do tvaru:

$$\begin{aligned}
BIC(p, q) = n \cdot \ln \hat{\sigma}_a^2 - (n - p - q) \ln \left(1 - \frac{p + q}{n} \right) \\
+ (p + q) \ln n + (p + q) \ln \left(\frac{\hat{\sigma}_z^2 - 1}{p + q} \right)
\end{aligned} \tag{5.14}$$

Kde $\hat{\sigma}_z^2$ je odhad rozptylu analyzované časové řady. Toto kritérium je označováno jako BIC (Bayesian Information Criterion).

Schwartzovo kritérium SC (Schwartz Criterion)

Další kritérium navrhl Schwartz ve formě:

$$SC(p, q) = n \cdot \ln \hat{\sigma}_a^2 + (p + q) \ln n \tag{5.15}$$

Hannan-Quinnovo kritérium HQ (Hannan-Quinn)

VARIANTOU Schwarzova kritéria je kritérium, které navrhli Hannan a Quinn ve formě:

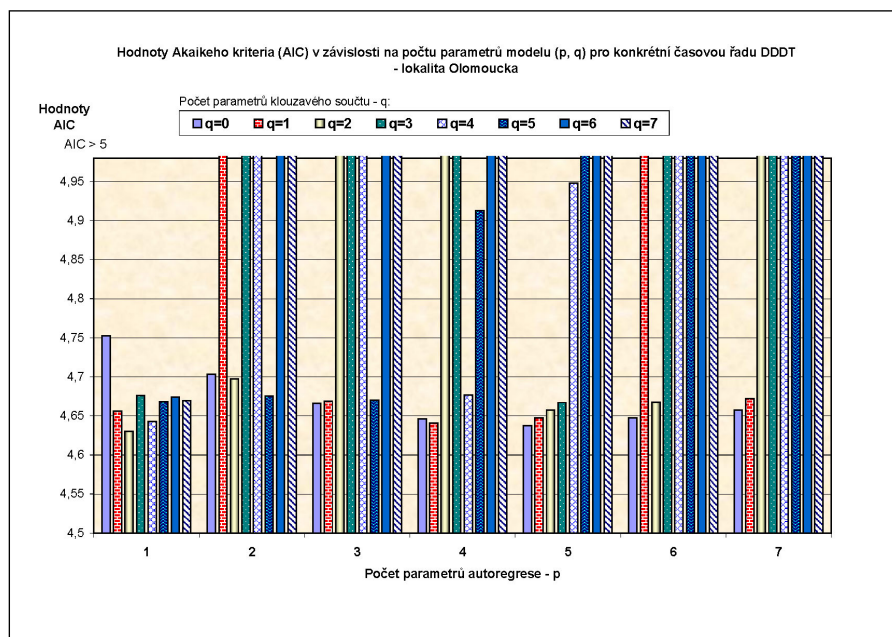
$$HQ(p, q) = n \cdot \ln \hat{\sigma}_a^2 + (p + q) \cdot c \cdot \ln(\ln n) \tag{5.16}$$

Kde c je konstanta, kterou je třeba volit. Hannan dokázal, že při volbě $c > 2$ je při minimální hodnotě kritéria odhad řádu modelu silně konzistentní.

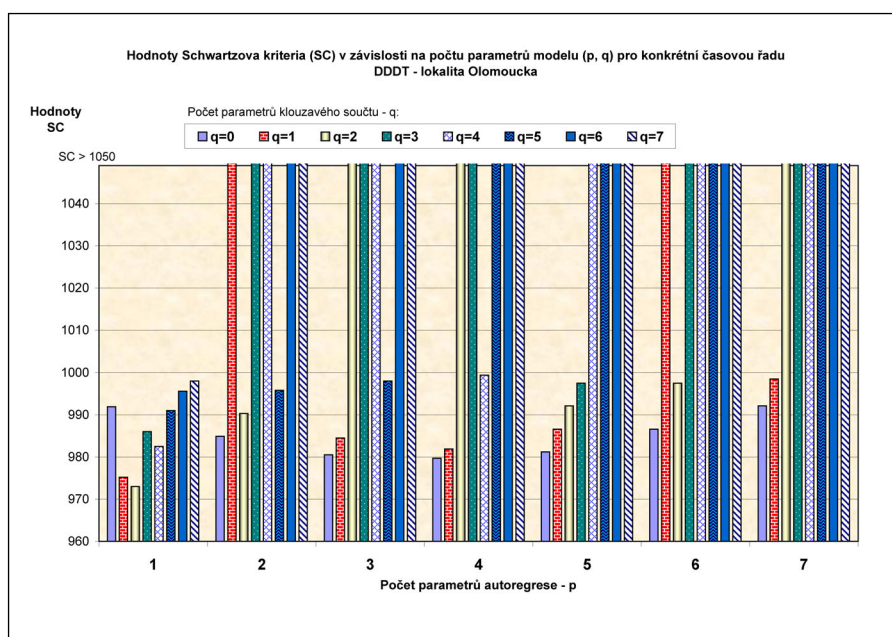
Další kritéria a podrobnější popis můžeme najít např. v [Cromwell a kol., 1994].

Aplikace kritérií pro odhad modelu konkrétní časové řady DDDT

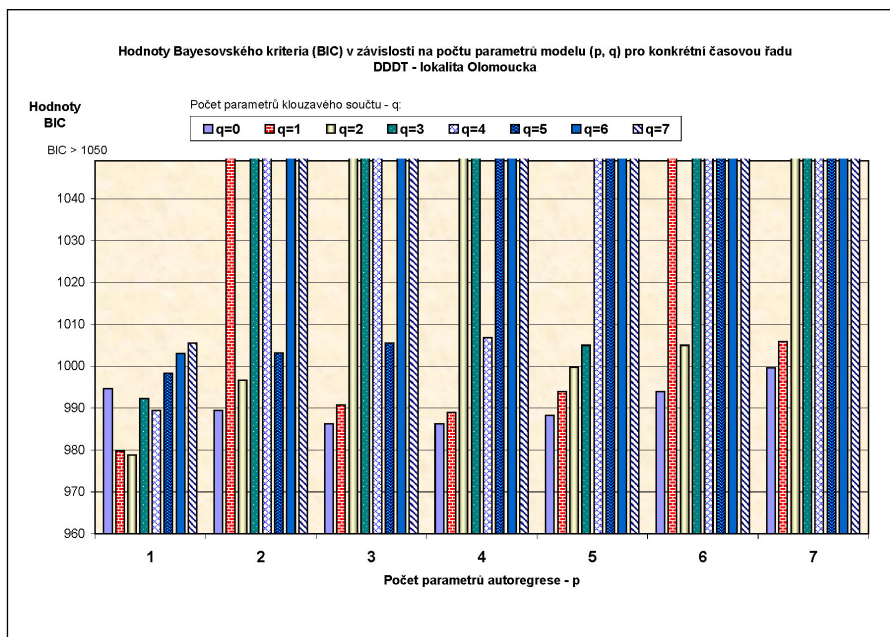
V další části se pokusíme prezentovat výsledky některých kritérií pro konkrétní časové řady DDDT a to jak pro lokalitu Olomoucka tak i pro lokalitu Zlínka. Výsledky jsou zachyceny v grafické podobě. Grafy, které vyjadřují závislost hodnoty zvoleného kritéria na počtu parametrů matematického modelu (p, q), jsou zobrazeny na Obr. 5.17 - Obr. 5.22. Chybí zde výsledky jen Hannan-Quinnova kritéria, kde je průběh podobný jako pro kritérium Schwartzovo.




Obr. 5.17: Hodnoty Akaikeho kriteria (AIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Olomoucka



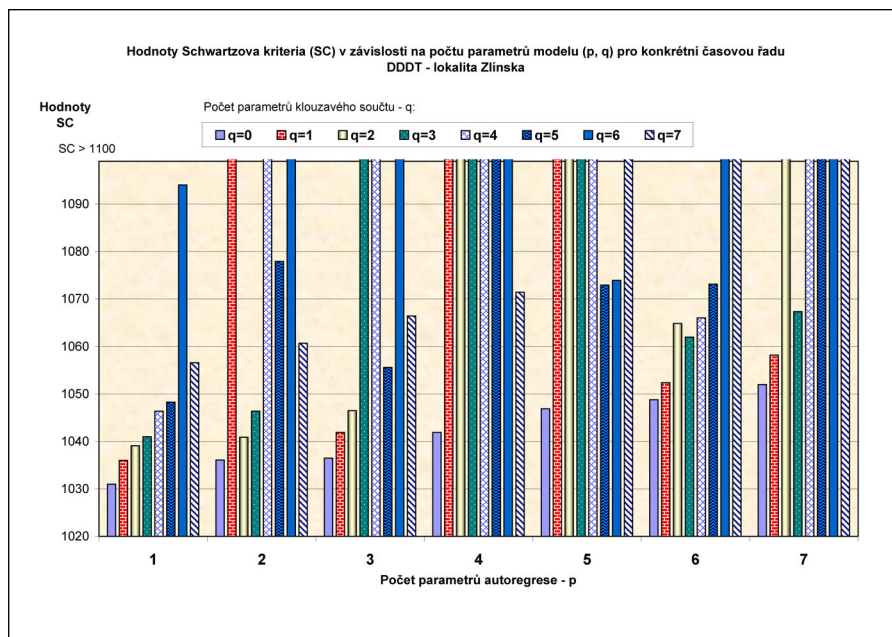
Obr. 5.18: Hodnoty Schwartzova kriteria (SC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Olomoucka



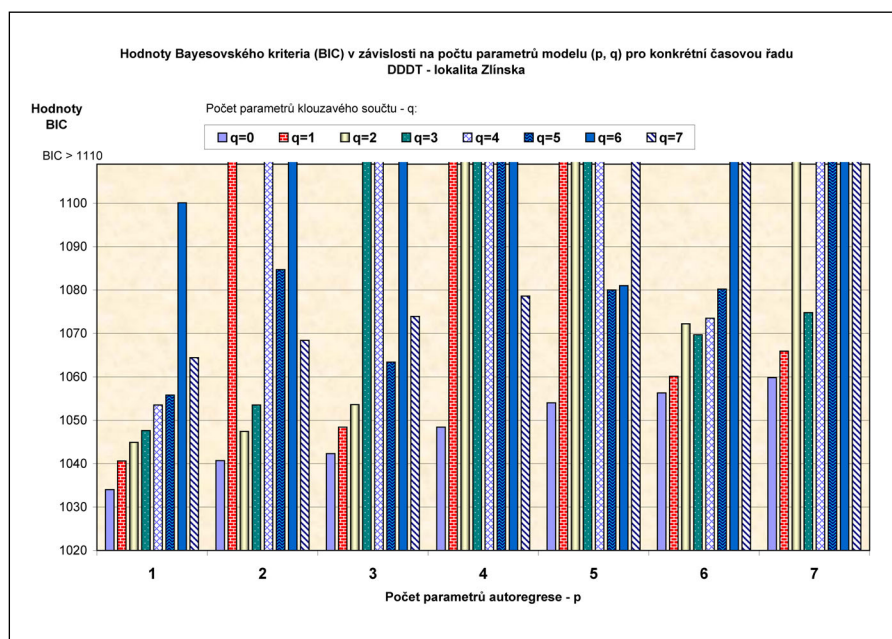
Obr. 5.19: Hodnoty Bayesovského kritéria (BIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Olomoucka



Obr. 5.20: Hodnoty Akaikeho kritéria (AIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Zlinska



Obr. 5.21: Hodnoty Schwartzova kriteria (SC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Zlínka




Obr. 5.22: Hodnoty Bayesovského kriteria (BIC) v závislosti na počtu parametrů modelu (p, q) pro konkrétní časovou řadu DDDT - lokalita Zlínka


Z grafických průběhů hodnot kritérií pro časovou řadu DDDT z lokality Olomoucka vidíme, že minimální hodnota všech kritérií připadá na hodnoty $p=1$ a $q=2$. Pro časovou řadu DDDT z lokality Zlínska nejsou výsledky tak jednoznačné. Při použití kritéria AIC dostaneme minimum pro hodnoty $p=3$ a $q=0$, kdežto při použití kritéria BIC resp. SC získáme minimální hodnoty pro volbu $p=1$ a $q=0$. Proto podrobíme tuto situaci detailnější analýze. K tomu využijeme srovnání výsledků průběhu předpovědi pro volbu $p=1, q=0$ a $p=3, q=0$. Tyto grafické průběhy jsou naznačeny na Obr. 5.23 a Obr. 5.24. Při srovnání výsledků je vidět že rozdíly jsou opravdu minimální a můžeme tedy pro předpověď časové řady DDDT použít jak model s parametry $p=3$ a $q=0$ tak i model s parametry $p=1$ a $q=0$. Ke stejnému závěru bychom došli kdybychom podrobněji analyzovali hodnoty kritérií pro oba modely. Z grafu hodnot kritéria AIC je vidět že pro volbu $p=1$ a $q=0$ je hodnota dostatečně malá a blízká minimální hodnotě. Totéž platí pro hodnotu kritéria BIC resp. SC pro volbu $p=3$ a $q=0$.

Pozn. V grafech na Obr. 5.23 a Obr. 5.24 je zobrazen jednak grafický průběh skutečných hodnot časové řady DDDT, dále predikované hodnoty na dva dny dopředu a také pásmo pravděpodobnosti.

Z grafických průběhů hodnot kritérií lze potvrdit obecnou teorii, že řád modelu p a q není obvykle příliš vysoký. Svědčí o tom nízké hodnoty kritérií pro nižší p a q .



Obr. 5.23: Průběh předpovědi časové řady DDDT – lokalita Zlínska pro volbu $p=1, q=0$.



Obr. 5.24: Průběh předpovědi časové řady DDDT – lokalita Zlínka pro volbu $p=3$, $q=0$.

5.3 Metody výpočtu předpovědi DDDT

Jak již bylo dříve uvedeno, v Boxově-Jenkinsově metodologii lze modelovat pouze stacionární časové řady a obecný model Box-Jenkinse (4.41) dokáže pracovat pouze z jednou periodou sezónnosti. Průběh naší konkrétní časové řady DDDT (viz. Obr. 5.1 až Obr. 5.4) však obsahuje dvě periodicity. Jednak denní periodu, která je dána fluktuacemi odběru tepla během dne a týdenní perioda reprezentována poklesem odběru tepla v sobotu a neděli. Obecný model Box-Jenkinse nám však neumožňuje popis a tedy ani predikci průběhu DDDT, protože nelze současně vystihnout denní a týdenní periodu časové řady. Abychom vystihli obě periody sezónnosti je třeba navrhnout složitější postup. Proto byly použity dva možné přístupy k výpočtu předpovědi DDDT:

- metoda, která využívá model s dvojnásobnou filtrací
- metoda superpozice modelů

5.3.1 Metoda využívající model s dvojnásobnou filtrací

Model s dvojnásobnou filtrací můžeme zjednodušeně vyjádřit prostřednictvím substituce (4.55) ve tvaru:

$$z_t = F \cdot \nabla_{s^*}^{D^*} \cdot a_t \quad (5.17)$$

kde rozlišíme symboly

D	stupeň sezónních diferencí denních (obsaženo v (4.54))
D*	stupeň sezónních diferencí týdenních
s	perioda sezónnosti denní (obsaženo v (4.54))
s*	perioda sezónnosti týdenní

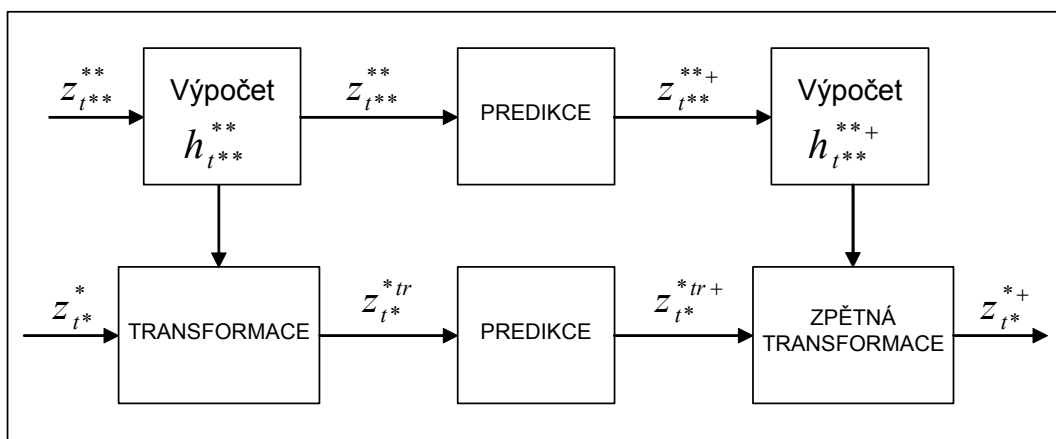
Při použití metody s dvojnásobnou filtrací je nutné dodržet při výpočtu predikce DDDT tento obecný postup :

- a) Provést sezónní diferencování časové řady z důvodu odstranění týdenní periodicity časové řady.
- b) Takto filtrovanou časovou řadu podle bodu a) lze pak vyjádřit obecným modelem Box-Jenkinse a provést výpočet predikce podle postupu uvedeného v kapitole 4.2.1.
- c) Je nutné provést zpětnou filtraci, která je inverzní k bodu a), protože jsme prováděli odstranění týdenní periodicity.

Model ve tvaru (5.17) umožňuje popsat průběh DDDT (tzn. popisuje periodickou složku denní i týdenní) a může být tedy použit pro analýzu a predikci sledovaných pravidelných kalendářních vlivů (soboty, neděle).

5.3.2 Metoda superpozice modelů

Pro odstranění pravidelných kalendářních vlivů (soboty, neděle), lze použít druhou metodu, tzv. *metodu superpozice modelů*. Tato metoda byla publikována v práci [Dostál, 1986]. Při této metodě se využívá dvou modelů ve tvaru (4.55), které rozlišíme symboly * a **. Časová řada označená *, je řada hodnot odběrů tepla pro danou vzorkovací periodu (např. 1 hodina, 30 minut, 15 minut, 10 minut) a časová řada označená **, je sumovaná řada hodnot odběrů tepla za 1 den (zvolená perioda vzorkování 24 hodin). Postup výpočtu predikce metodou superpozice modelů se provádí způsobem, který je detailně popsán níže a názorně zobrazen na Obr. 5.25.



Obr. 5.25: Postup výpočtu predikce metodou superpozice modelů

Postup výpočtu metodou superpozice modelů

Postup je naznačen pro vzorkovací periodu časové řady z_{t^*} 1 hodina.

1. Výpočet sumované denní časové řady $z_{t^{**}}$ podle vzorce:

$$z_{t^{**}+1} = \sum_{i=1}^{24} z_{(t^{**} \cdot 24)+i}^* \quad \text{pro } t^{**} = 0, 1, 2, \dots, N^{**} - 1 \quad (5.18)$$

kde N^{**} je počet hodnot sumované denní časové řady $z_{t^{**}}$

2. Výpočet koeficientů normování $h_{t^{**}}$ podle vzorce:

$$h_{t^{**}} = \frac{z_{stř}^{**}}{z_{t^{**}}} \quad \text{pro } t^{**} = 1, 2, 3, \dots, N^{**} \quad (5.19)$$

kde $z_{stř}^{**}$ je hodnota aritmetického průměru časové řady $z_{t^{**}}$ a je vypočítána podle vzorce:

$$z_{stř}^{**} = \frac{1}{N^{**}} \cdot \sum_{i=1}^{N^{**}} z_i^{**} \quad (5.20)$$

3. Provedeme normování časové řady z_{t^*} podle vztahu:

$$z_{t^*}^{*norm} = h_{t^{**}} \cdot z_{t^*} \quad \text{pro } t^* = 1, 2, \dots, N^* \quad (5.21)$$

Vysvětlení vztahu mezi indexy času t^* a t^{**} je uvedeno níže.

4. Následuje výpočet matematického modelu Box-Jenkinse a predikce časových řad $z_{t^*}^{*norm}$ a $z_{t^{**}}^{**}$ podle kapitoly 4.2.1. Takto získáme predikované hodnoty $z_{t^*}^{*norm+}$ a $z_{t^{**}}^{**+}$.

5. Výpočet koeficientů normování $h_{t^{**}}^{**+}$ v předpověděné časové řadě podle vztahu:

$$h_{t^{**}}^{**+} = \frac{z_{t^{**}}^{**}}{z_{t^{**}}^{**+}} \quad \text{pro } t^{**} = 1, 2, 3, \dots, N^{**} + u^{**} \quad (5.22)$$

kde $u^{**} = 1, 2, \dots, L^{**}$, je hodnota reprezentující časový předstih v sumované denní časové řadě (tj. počet dnů predikce). L^{**} je pak maximální hodnota časového předstihu.

6. Protože jsme prováděli normování časové řady $z_{t^*}^*$ podle vztahu (5.21) je nutné provést zpětné normování časové řady $z_{t^*}^{*norm+}$ podle vztahu:

$$z_{t^*}^{*+} = \frac{z_{t^*}^{*norm+}}{h_{t^*}^{**+}} \quad \text{pro } t^* = 1, 2, \dots, N^* + u^* \quad (5.23)$$

kde $u^* = 1, 2, \dots, L^*$, je hodnota reprezentující časový předstih v původní časové řadě (tj. počet hodnot predikce). L^* je pak maximální hodnota časového předstihu.


POZN: Vysvětlení vztahu mezi indexy času t^* a t^{**} :

Vztah mezi indexy času definujeme jako:

$$t^{**} = \text{ent}^1 \left(1 + \frac{t^* + u^* - 1}{24} \right) \quad \text{pro } u^* = 1, 2, \dots, L^* \quad (5.24)$$

Zavedení vzorce (5.24) je nutné pro výpočet na počítači. Důvodem jsou různé délky časových úseků řady $z_{t^*}^*$ a $z_{t^{**}}^{**}$. Význam tohoto vzorce je patrný z časových os na obr.18, kde je vykreslena závislost t^* a t^{**} .

¹ Entier (ent) je název standardní matematické funkce




Obr. 5.26: Závislost mezi indexy časů t^* a t^{**} .

Postup metody superpozice modelů umožňuje popsat průběh DDDT SCZT (tzn. popisuje periodickou složku denní i týdenní) a může být tedy použit pro analýzu a predikci sledovaných pravidelných kalendářních vlivů (soboty, neděle).

5.4 Způsob výpočtu predikce DDDT


Pro volbu adekvátního typu modelu byla použita kritéria, která jsou založena na porovnání reziduí jednotlivých modelů pomocí sumárních statistik. V našem případě jsme použili kritérium Akaikeho (AIC). Princip hledání adekvátního modelu pomocí kritéria AIC je pak následující. Nejdříve je nutné předem zadat horní hranice p_{max} a q_{max} pro hledaný správný řád modelu ARMA. Čísla p_{max} a q_{max} může přímo volit uživatel, ale doporučují se hodnoty maximálně $p_{max} = q_{max} = 7$. Dále pro všechny takto získané modely určíme hodnotu rozptylu reziduí $\hat{\sigma}_a^2$, která je funkcí parametrů p a q . Následně pak stanovíme hodnotu kritéria $AIC(p,q)$ podle vzorce (5.13). Za adekvátní model se pak bere model s parametry p a q pro které je hodnota AIC kritéria minimální.

U predikce nás bude zajímat také tzv. *pásma pravděpodobnosti*, které vyjadřuje oblast výskytu budoucích hodnot se zvolenou pravděpodobností. Šíře pásma pravděpodobnosti závisí na zvolené pravděpodobnosti výskytu budoucích hodnot, přesnosti modelu, vyjadřujícího skutečnost a na volbě hodnoty časového předstihu. Grafická ukázka je na Obr. 5.27.



Obr. 5.27: Ukázka grafického znázornění predikce s pásmem pravděpodobnosti 50% a 95%

Při výpočtu predikce průběhu DDDT v reálném čase lze využít metody tzv. posouvajícího se horizontu. Touto metodou se rozumí, že výpočet prognózy opakujeme se zvolenou vzorkovací periodou (10 minut, 15 minut, 30 minut nebo 1 hodina) a s konstantním počtem N hodnot DDDT. Na Obr. 5.28 je znázorněn způsob záměny nové hodnoty za starou, kdy po každém měření by došlo k přesunu hodnot řady DDDT podle naznačeného postupu. Takže vždy po uplynutí vzorkovací periody je časová řada DDDT posunuta a je proveden nový výpočet predikovaných hodnot časové řady.



Obr. 5.28: Metoda posouvajícího se horizontu

5.5 Zahrnutí nepravidelných kalendářních vlivů

Kalendářní vlivy, tj. pracovní dny (pondělí-pátek) a dny pracovního volna (sobota, neděle) již popsany postup řešení předpovědi postihuje. Použitá metoda předpovědi však nezahrnuje tzv. *nepravidelné kalendářní vlivy*. Jedná se o situaci, kdy státem uznávaný

svátek respektive den pracovního klidu případně na pracovní den. V takovém případě je nutné při výpočtu předpovědi učinit opatření pro korekci takových vlivů.

Korekce nepravidelných kalendářních vlivů vychází z předpokladu, že dodávka tepla v nepravidelném nepracovním dnu se chová jako v neděli. Na základě předchozího předpokladu zavádíme následující korekční koeficienty:

$$S_i^{Po} = \frac{z_i^{Ponděli}}{z_i^{Neděle}} \quad (5.25)$$

$$S_i^{Út} = \frac{z_i^{Úterý}}{z_i^{Neděle}} \quad (5.26)$$

$$S_i^{St} = \frac{z_i^{Středa}}{z_i^{Neděle}} \quad (5.27)$$

$$S_i^{Čt} = \frac{z_i^{Čtvrtek}}{z_i^{Neděle}} \quad (5.28)$$

$$S_i^{Pá} = \frac{z_i^{Pátek}}{z_i^{Neděle}} \quad (5.29)$$

kde pro vzorkovací periodu 1 hodina

i - hodina dne $i=0,1,2, \dots, 23$

z_i – reálná hodnota odběru tepla v i -tou hodinu daného dne

Tyto korekční koeficienty jsou získány z naměřených hodnot odběru tepla v jednotlivých hodinách daného dne předchozího týdne.

Poznámka: Průběh některých časových řad v neděli před dnem pracovního klidu je jiný než před klasickým pracovním dnem. V tomto případě musíme korekční koeficient pro pondělí získat z naměřených hodnot odběru tepla v jednotlivých hodinách pondělí a neděle 2 týdny nazpět.

Poznámka: Při jiné vzorkovací jednotce např. 30 minut jsou při výpočtu korekčních koeficientů využity hodnoty odběru tepla za každých 30 minut. Symboly použité ve vzorcích pro výpočet korekčních koeficientů pak budou mít význam:

i - půlhodina dne $i=0,1,2, \dots, 47$

z_i – reálná hodnota odběru tepla v i -tou půlhodinu daného dne

Korigované hodnoty předpovědi odběru tepla v nepravidelný den pracovního klidu připadající na pracovní den dostáváme pak podle vztahu:

$$z_i^{den+*} = \frac{z_i^{den+}}{S_i^{den}} \quad (5.30)$$

kde z_i^{den+} je predikovaná hodnota odběru tepla pro i -tou hodinu daného dne,

z_i^{den+*} je korigovaná hodnota předpovědi odběru tepla pro i -tou hodinu daného dne,

S_i^{den} je korekční koeficient pro i -tou hodinu daného dne.

Protože používáme metodu posouvajícího se horizontu a naměřené reálné hodnoty odběru tepla v tento nepravidelný den pracovního klidu vstupují do výpočtu predikce na další dny je potřeba těmto údajům vrátit charakter pracovního dne, aby nám neovlivnily průběh předpovědi DDDT na další dny. Z tohoto důvodu je třeba provést zpětnou korekci reálných dat podle vztahu:

$$z_i^{den*} = z_i^{den} \cdot S_i^{den} \quad (5.31)$$

kde z_i^{den} je naměřená reálná hodnota odběru tepla pro i -tou hodinu daného nepravidelného dne pracovního klidu,

z_i^{den*} je zpětně korigovaná hodnota naměřeného reálného odběru tepla pro i -tou hodinu daného nepravidelného dne pracovního klidu,

Typickým příkladem, kdy je třeba realizovat korekci na nepravidelné kalendářní vlivy je velikonoční pondělí. Vyjdeme tedy z předpokladu, že dodávka tepla bude mít charakter jako v neděli. Vypočítáme proto korekční koeficient S_i^{Po} pomocí vztahu (5.25).

Po výpočtu předpovědi průběhu DDDT ať už metodou dvojí filtrace nebo metodou superpozice modelů je třeba predikované hodnoty připadající na velikonoční pondělí korigovat podle vztahu (5.32), který vychází z obecného vztahu (5.30).

$$z_i^{Po+*} = \frac{z_i^{Po+}}{S_i^{Po}} \quad (5.32)$$

kde z_i^{Po+} je predikovaná hodnota odběru tepla pro i -tou hodinu velikonočního pondělí,

z_i^{Po+*} je korigovaná hodnota předpovědi odběru tepla pro i -tou hodinu velikonočního pondělí,

S_i^{Po} je korekční koeficient pro i -tou hodinu pondělí.

Vzhledem k tomu že obecně je pondělí dnem pracovním musí do modelu pro výpočet předpovědi vstupovat jako den pracovní aby nám neovlivňoval hodnoty odběru tepla předpověděné pro další dny. Velikonoční pondělí je dnem nepracovním, proto musíme provést zpětnou korekci naměřených reálných hodnot odběru tepla tak, aby jejich průběh měl povahu pracovního pondělí. Zpětnou korekci provedeme podle vztahu (5.33), který vychází z obecného vztahu (5.31).

$$z_i^{Po*} = z_i^{Po} \cdot S_i^{Po} \quad (5.33)$$

kde z_i^{Po} je naměřená reálná hodnota odběru tepla pro i -tou hodinu velikonočního pondělí,

z_i^{Po*} zpětně korigovaná hodnota naměřeného reálného odběru tepla pro i -tou hodinu velikonočního pondělí,

S_i^{Po} korekční koeficient pro i -tou hodinu pondělí.

Takto korigované reálné hodnoty odběru tepla na velikonoční pondělí je možné zahrnout do modelu pro výpočet předpovědi v dalších krocích aniž by došlo k ovlivnění následných výsledků.

Pokud se vyskytne nepravidelný den pracovního klidu v jiném dnu v týdnu, postup korekce je stejný s tím rozdílem, že používáme korekční koeficient vztahující se ke dni ve

kterém tato situace nastala. Např. případně-li den pracovního klidu na středu použijeme korekční koeficient S_i^{St} vypočtený podle vztahu (5.27).

5.6 Zahrnutí vlivu venkovní teploty na průběh DDDT

Oba dva popsané přístupy řešení předpovědi DDDT tj. metoda dvojí filtrace a metoda superpozice modelů umožňují současně vystihnout denní a týdenní periodu časové řady DDDT. Tyto metody umožňují dále modelovat také trend, který je dán plynulými přechody mezi ročními obdobími tj. poklesem respektive růstem venkovní teploty v průběhu roku. Použité metody předpovědi však nezahrnují vliv náhlých změn meteorologických veličin. Jedná se o situaci, kdy se objeví náhlé výkyvy počasí. V takovém případě je nutné do výpočtu předpovědi zahrnout vliv meteorologických veličin.

Práce, které vznikly na toto téma např.[Arvastson, 2001] uvádí, že největší vliv na průběh DDDT, co se týká meteorologie, má velikost venkovní teploty. Této skutečnosti jsme využili i v naší práci a zahrnuli jsme do výpočtu předpovědi DDDT vliv venkovní teploty vzduchu. Další meteorologické vlivy jako jsou rychlost a směr větru, intenzita slunečního záření, barometrický tlak, vlhkost a další jsou částečně obsaženy v náhodné složce.

Pro zahrnutí vlivu venkovní teploty do výpočtu předpovědi DDDT byl navržen následující postup:

- a) Odfiltrovat z časové řady DDDT vliv venkovní teploty využitím korekční topné charakteristiky.
- b) Pro takto filtrovanou časovou řadu podle bodu a) provést výpočet předpovědi prostřednictvím modelu s dvojnásobnou filtrací nebo metodou superpozice modelů.
- c) Provést zpětnou filtraci předpověděných hodnot na základě předpovědi počasí, kdy zahrneme vliv předpovídané venkovní teploty.

Z navrženého postupu je patrné, že hlavním cílem je vyjádřit explicitně závislost odběru tepla na venkovní teplotě – ***korekční topnou charakteristiku***. Z další úvahy je

zřejmé, že tato závislost není lineární. Pro relativně vysoké teploty, má venkovní teplota malý vliv na odběr tepla. Například odběr tepla pro teplotu 25°C a 27°C je téměř stejný. Podobné je to i pro relativně nízké teploty. Například není rozhodující jestli je teplota -28°C nebo -30°C, protože výrobní jednotka jede při těchto teplotách na maximální výkon. Na základě těchto úvah je možné závislost odběru tepla na venkovní teplotě – *korekční topnou charakteristiku* napsat ve tvaru:


$$z_t^{kor} = x_1 \cdot T_t^3 + x_2 \cdot T_t \quad (5.34)$$

kde z_t^{kor} je korekční hodnota odběru tepla v čase t zahrnující vliv venkovní teploty,

T_t je reálná naměřená hodnota venkovní teploty v čase t ,

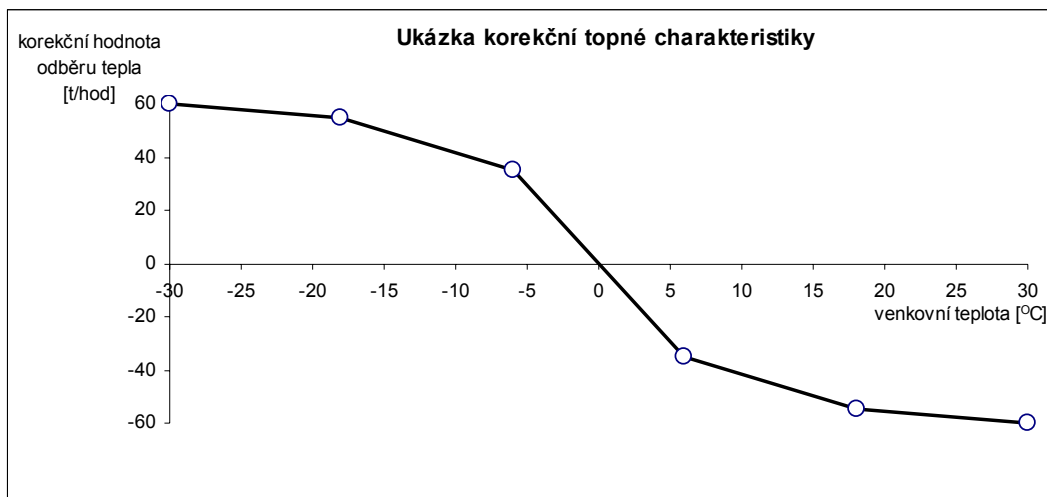
x_1, x_2 jsou konstanty

Průběh korekční topné charakteristiky pro konstanty např. $x_1 = 0.002, x_2 = -3.5$ je vykreslen na Obr. 5.29 .



Obr. 5.29: Ukázka průběhu korekční topné charakteristiky – kubická fce

Jinou možností je vyjádřit závislost odběru tepla na teplotě pomocí po částech se měnící lineární funkcí. Ilustrační příklad je vidět na Obr. 5.30



Obr. 5.30: Ukázka průběhu korekční topné charakteristiky – po částech lineární funkce

V našem příkladu je použita funkce s pěti segmenty. Počet segmentů je samozřejmě možné libovolně měnit. Označme počet segmentů jako N_s . Pokud známe (popřípadě zvolíme) hodnoty venkovní teploty tj. $\tau_i, i = 1, \dots, N_s + 1$, ve kterých se mění parametry funkce můžeme zapsat výslednou funkci ve tvaru:

$$z_t^{kor} = \alpha_i \cdot T_t + \beta_i \quad \text{pro } \tau_i < T_t < \tau_{i+1}, \quad i = 1, \dots, N_s \quad (5.35)$$

kde z_t^{kor} je korekční hodnota odběru tepla v čase t zahrnující vliv venkovní teploty,

T_t je reálná naměřená hodnota venkovní teploty v čase t ,

α_i je směrnice přímky v i -tém segmentu funkce

β_i je absolutní člen rovnice přímky v i -tém segmentu funkce

Konstanty α_1, α_2 resp. α_i, β_i je možné určit empiricky pro danou lokalitu. V našem případě jsme hledání těchto konstant převedli na optimalizační problém. Kriteériem byla minimální hodnota rozptylu sezónně filtrované časové řady z_t^{filtr} (viz rovnice (5.36).

Filtrovanou časovou řadu DDDT, která pak vstupuje do modelu pro výpočet předpovědi můžeme psát ve tvaru:

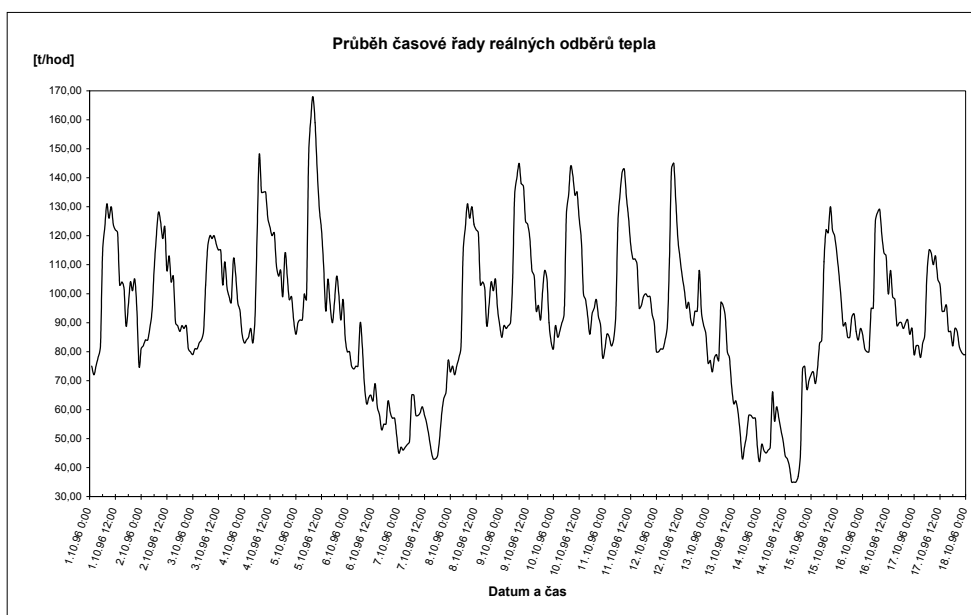
$$z_t^{filtr} = z_t - z_t^{kor} \quad (5.36)$$

kde z_t^{filtr} je hodnota odběru tepla v čase t s odfiltrováním vlivu venkovní teploty,

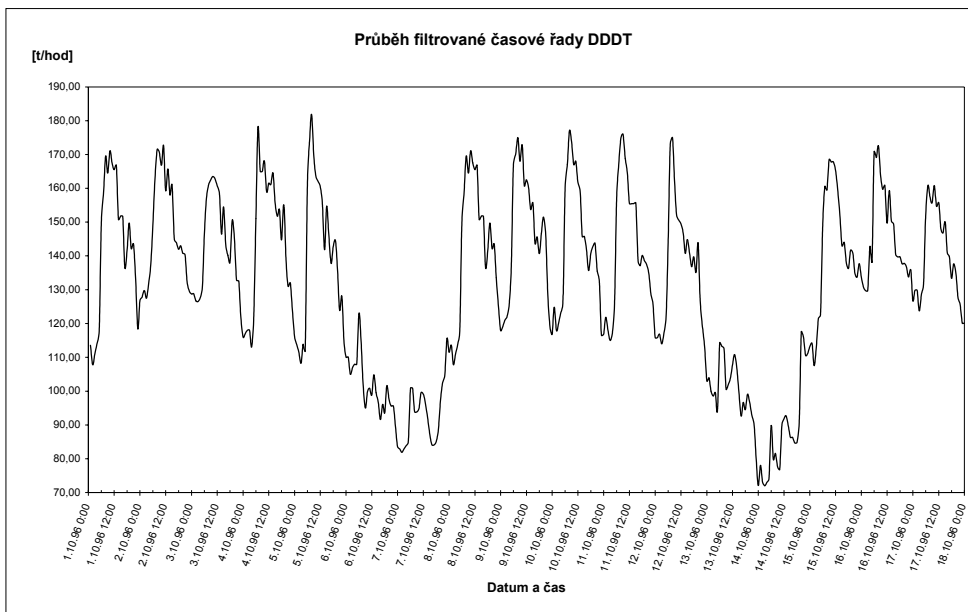
z_t^{kor} - korekční hodnota odběru tepla v čase t zahrnující vliv venkovní teploty,

z_t - reálná hodnota odběru tepla v čase t .

Reálný průběh časové řady z_t resp. z_t^{filtr} je demonstrován na obrázcích Obr. 5.31 a Obr. 5.32. V našem případě bylo využito reálných dat získaných v Teplárně Otrokovice, a korekční charakteristika byla uvažována ve tvaru kubické křivky s konstantami $x_1 = 0.002$, $x_2 = -3.5$



Obr. 5.31: Reálný průběh časové řady DDDT



Obr. 5.32: Reálný průběh filtrované časové řady DDDT

Po provedení výpočtu předpovědi časové řady \bar{z}^{filtr} je nutné provést zpětnou filtraci předpověděných hodnot z důvodu zahrnutí vlivu venkovní teploty. Tuto operaci můžeme zapsat ve tvaru:

$$z_t^+ = z_t^{filtr+} + z_t^{kor} \quad (5.37)$$

kde z_t^{filtr+} je predikovaná hodnota odfiltrované řady odběru tepla v čase t ,


z_t^{kor} je korekční hodnota odběru tepla v čase t zahrnující vliv venkovní teploty,

z_t^+ je predikovaná hodnota odběru tepla v čase t .


Hodnotu z_t^{kor} pro zpětnou filtraci získáme výpočtem podle vztahu (5.34) respektive (5.35). Za hodnoty T_t budeme dosazovat předpovídané teploty podle meteorologické předpovědi v čase t .

Jak to vypadá při konkrétním použití lze pro předchozí reálná data demonstrovat graficky. Průběh predikovaných hodnot odfiltrované časové řady odběru tepla je srovnáván s reálnými hodnotami odběrů (viz Obr. 5.33). Totéž srovnání je provedeno při

grafickém znázornění průběhu predikovaných hodnot DDDT po provedení zpětné filtrace (viz Obr. 5.34).



Obr. 5.33: Srovnání průběhu predikované časové řady DDDT se skutečnými odběry před zpětnou filtrací



Obr. 5.34: Srovnání průběhu predikované časové řady DDDT se skutečnými odběry po provedení zpětné filtrace

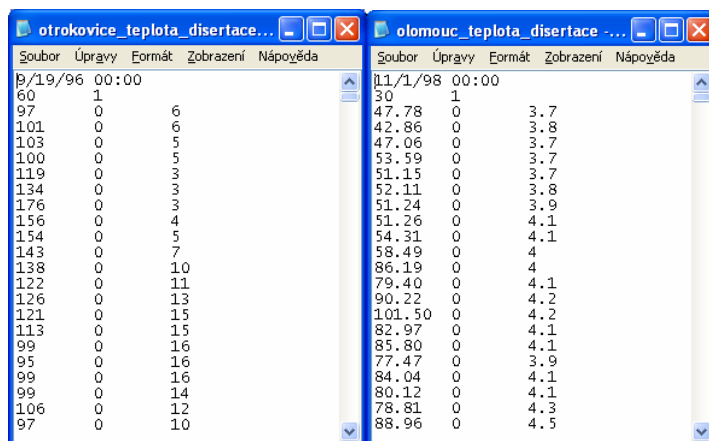
Pokud by ostatní meteorologické vlivy (směr větru, rychlost větru, intenzita slunečního záření, barometrický tlak, vlhkost a jiné) podstatně působily na velikost odběru tepla, můžeme je zahrnout do výpočtu předpovědi taktéž a to pomocí modifikace předchozí procedury. V tomto případě bude venkovní teplota v topné charakteristice korigována právě na aktuální hodnotu ovlivňující meteorologické veličiny.

6 EXPERIMENTÁLNÍ ČÁST

6.1 Program v prostředí MATLAB

Na základě předchozích teoretických rozborů a návrhů byl sestaven komplexní výpočtový program a to v uživatelsky jednoduchém prostředí pod operačním systémem Windows XP. Pro tvorbu samotného výpočetního programu bylo zvoleno programové prostředí MATLAB. Tento produkt je v současné době hodně rozšířen na vysokých školách technického typu a plně vyhovuje našim požadavkům pro matematické výpočty.

Uvedený program je koncipován do jednoduchých uživatelských nabídek a dovoluje nastavení celé řady parametrů výpočtu. Veškeré výpočty jsou založeny na spoustě skutečných dat, naměřených v určité lokalitě. V našem případě jsme získaly data z lokality Olomoucka a Zlínska, které nám poskytla MST, a.s. – Teplárna Olomouc resp. Teplárna Otrokovice. Tato data jsou pro další použití zpracována ve formě textového souboru. Ukázka částečného výpisu textových souborů s daty ze zmíněných lokalit je zobrazena na Obr. 6.1.



The image shows two side-by-side windows of a text editor in MATLAB. The left window is titled 'otrokovice_teplota_disertace...' and contains a list of data points with columns for date, time, and numerical values. The right window is titled 'olomouc_teplota_disertace...'. Both windows have a menu bar with 'Soubor', 'Úpravy', 'Formát', 'Zobrazení', and 'Nápověda'.

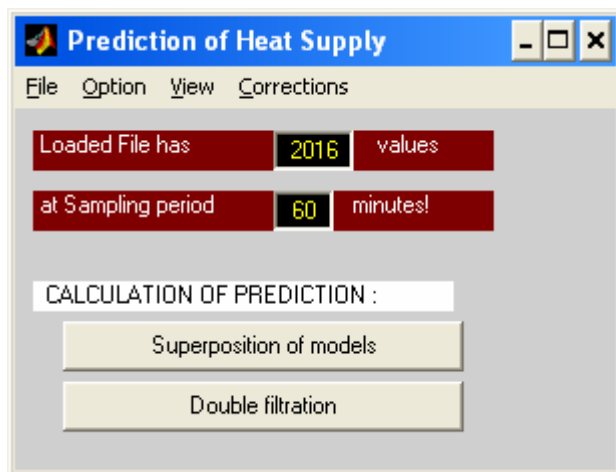
otrokovice_teplota_disertace...	olomouc_teplota_disertace...
09/19/96 00:00	11/1/98 00:00
60 1	30 1
97 0	47.78 0
101 0	42.86 0
103 0	47.06 0
100 0	53.59 0
119 0	51.15 0
134 0	52.11 0
176 0	51.24 0
156 0	51.26 0
154 0	54.31 0
143 0	58.49 0
138 0	86.19 0
122 0	79.40 0
126 0	90.22 0
121 0	101.50 0
113 0	82.97 0
99 0	85.80 0
95 0	77.47 0
99 0	84.04 0
99 0	80.12 0
106 0	78.81 0
97 0	88.96 0

Obr. 6.1: Částečný výpis textových souborů s daty z lokality Zlínska a Olomoucka

První řádek souboru reprezentuje datum první datové hodnoty, druhý řádek obsahuje dvě položky. První položka představuje vzorkovací periodu získaných dat. Druhá položka informuje jestli jsou v souboru obsažena data s hodnotami venkovní teploty. Dále

následuje výpis jednotlivých datových hodnot v pořadí odběr tepla, jestli se jedná o svátek (1) či nikoliv (0) a hodnota venkovní teploty.


Po spuštění samotného programu je nutné nejdříve nahrát balík skutečných dat, které jak jsme uvedly máme uloženy ve formě textového souboru. Po načtení skutečných dat máme přehled o počtu dat, které jsou k dispozici a také s jakou periodou byla tato data získána. Ukázka takového vstupního okna je vidět na Obr. 6.2.



Obr. 6.2: Vstupní okno výpočetního programu

Nyní je naší povinností, nastavit parametry celého výpočtu. To lze provést pomocí jednotlivých položek v nabídce „*Option*“. Mezi nastavitelné parametry výpočtu patří:

„*Model Order*“ – řád modelu. Zde máme možnost nastavit parametry modelu p a q (zvolit počet parametrů autoregrese a počet parametrů klouzavého součtu pro matematický statistický model). Nabídka obsahuje dvě položky jak je vidět na Obr. 6.3:



Obr. 6.3: Okno nastavení řádu modelu

„*Set the Order of Model*“ - parametry p a q statistického matematického modelu stanoví uživatel ručně.

„*Optimal Order of Model*“ - program vybere parametry modelu p a q sám v rozsahu, který si může uživatel sám zvolit např. 0-7 (kritériem je minimální hodnota Akaikeho kriteria - AIC).

„*Prediction Length*“ - počet předpovídaných hodnot.

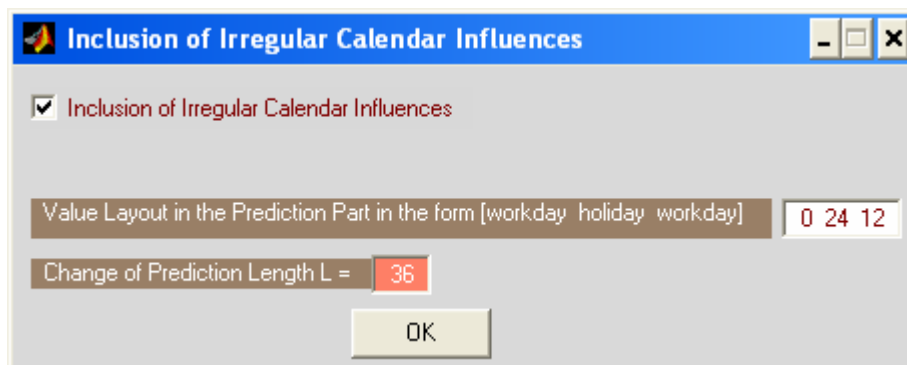
„*Sampling Period*“ – volba různé vzorkovací periody (10 minut, 15 minut, 30 minut, 1 hodina), volba je závislá na periodě skutečných dat, které máme k dispozici.

„*Historical Area*“ – volba počátku historické oblasti, ze které se vychází při výpočtu předpovědi. (Pozn. k výpočtu je využito historických hodnot v délce 17 dnů, tj. 408 hodnot při periodě 1 hodina)

„*Probability Limit*“ – oblast výskytu budoucích hodnot se zvolenou pravděpodobností (50%, 75%, 90%, 95%, 99%).

„*Data Smoothing*“ – nastavení jestli chceme použít vyrovnání(vyhlazení) časové řady. Detailní popis byl uveden v kapitole 5.2.1.

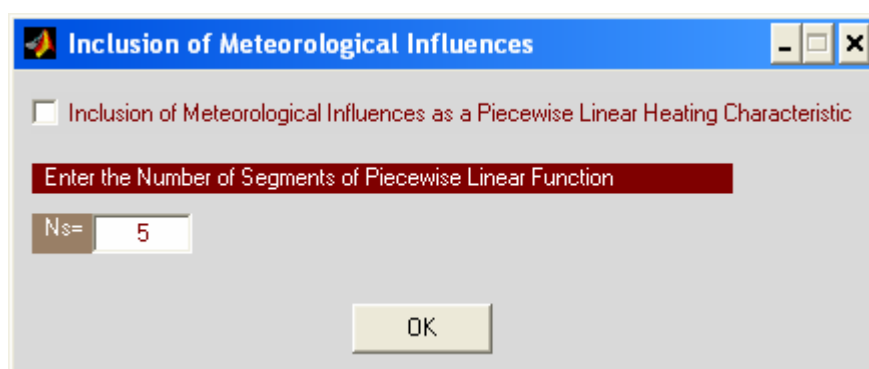
Důležitou součástí předkládaného programu je zahrnutí kalendářních vlivů a meteorologických vlivů do výpočtu předpovědi DDDT. Nastavení parametrů pro zahrnutí těchto vlivů lze realizovat prostřednictvím jednotlivých položek nabídky „*Corrections*“. První položkou je „*Calendar Influences*“ viz Obr. 6.4.



Obr. 6.4: Okno pro nastavení výpočtu se zahrnutím kalendářních vlivů

V případě zahrnutí kalendářních vlivů je nejdůležitější nastavit rozložení predikovaných hodnot. Tzn. jestli předpovídáme hodnoty pro den pracovního klidu, který připadá na den pracovní, popřípadě kolik hodnot se vztahuje ke dni pracovnímu (nekorigovanému) ať již před svátkem nebo po svátečním dnu. Konkrétně pro případ, který je ilustrován na Obr. 6.4 předpovídáme 24 hodnot svátečního dne a 12 hodnot ze dne následujícího po svátku. Ve spodní části okna se zobrazuje pro informaci celkový počet předpovídaných hodnot. Pro zahrnutí těchto nastavení ve výpočtu je nutné zatrhnout zaškrťávací pole v horní části okna.

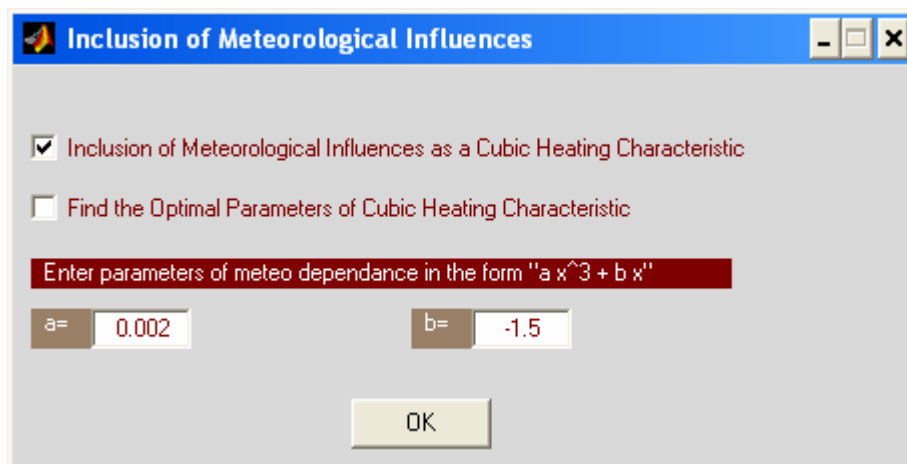
Druhou položkou nabídky „*Corrections*“ je položka „*Meteo Influences*“. Zde můžeme zvolit tvar závislosti odběru tepla na venkovní teplotě. Jak bylo uvedeno v kapitole 5.6 můžeme použít buď po částech se měnící lineární funkci zapsanou ve tvaru (5.35) nebo funkci kubickou ve tvaru (5.34). U nastavení závislosti odběru tepla na venkovní teplotě pomocí po částech se měnící funkce (viz Obr. 6.5) je nutné zadat počet segmentů této funkce. Jednotlivé parametry funkce hledá program sám, kde kritériem byla minimální hodnota rozptylu sezónně filtrované časové řady.



Obr. 6.5: Okno nastavení po částech se měnící funkce


U nastavení závislosti odběru tepla na venkovní teplotě pomocí kubické funkce (viz Obr. 6.6) máme možnost zvolit parametry funkce ručně nebo nechat program vyhledat optimální hodnoty, kde kritériem je opět minimální hodnota rozptylu sezónně filtrované časové řady.

Před spuštěním vlastního výpočtu předpovědi existuje ještě možnost v nabídce „View“ nastavit počet zobrazených historických hodnot ve výsledném grafu predikce a také počet zobrazených hodnot zpětné predikce.



Obr. 6.6: Okno nastavení kubické funkce

Po nastavení všech parametrů a po výběru jedné z metod (tj. kliknutím na příslušné tlačítko), se spouští vlastní výpočet předpovědi průběhu DDDT. Jak je vidět na Obr. 6.2, můžeme předpověď realizovat pomocí metody využívající model s dvojnásobnou filtrací nebo metodou superpozice modelů. Rozdíl v postupu řešení obou metod byl naznačen v části 5.3. Po provedení výpočtu se zobrazí výsledkové grafické okno (viz Obr. 6.7).



Obr. 6.7: Výstupní grafické okno

V tomto okně je názorně zobrazen průběh DDDT, je zde zakreslen průběh predikovaných hodnot a pásmo pravděpodobnosti výskytu budoucích hodnot. Průběh předpověděných hodnot je srovnáván s reálnými daty. V grafu existují dvě x-ové osy. Jedná se o denní osu a hodinovou časovou osu. Tzn. je zobrazen jak datum tak i čas.

Výsledky experimentu pro zvolený matematický model lze zobrazit samozřejmě ve formě konkrétních hodnot, které jsou při výpočtu sledovány. Výsledkové okno se sledovanými veličinami a nastavenými parametry, které lze aktivovat volbou v grafickém výstupním okně kliknutím na nabídku „**Results**“ je vidět na Obr. 6.8. Lze zobrazit výsledky jednak pro část zpětné predikce, jednak pro část dopředné predikce.

Parameters of Calculation: for Superposition of Models Method	
Sampling Period:	60 minutes
Prediction Length:	24 values
First historical Value:	289
Probability Limit:	90 %
Time Series Smoothing:	No
Calendar Influences:	No
Meteo Influences:	Method: Piecewise Linear Function Ns=5
Order of Model p= 2 q= 0 d= 1	
Ratio of Predicted Data Area and Real Data Area	88.1524 %
Standard Deviation of Error	5.668 t/hod
Average Relative Error	12.3347 %
Square root of MSE	9.0647 t/hod
Maximum Relative Error	-21.9029 %

OK

Obr. 6.8: Okno s výsledky experimentu

Při výpočtu předpovědi průběhu DDDT je pro dané parametry modelu p a q (popřípadě optimální hodnoty) resp. d sledována procentuální velikost plochy pod křivkou predikovaných hodnot v závislosti na ploše pod křivkou skutečných hodnot. Mírou věrohodnosti je dále druhá odmocnina ze střední kvadratické odchylky udávaná v $\frac{t}{hod}$, směrodatná odchylka chyby, průměrná relativní chyba a maximální relativní odchylka v procentech. Všechny sledované veličiny lze pak jednoduše uložit do textového souboru


přes nabídku „*Save Results*“ ve výsledkovém okně. Ve výstupním grafickém okně může uživatel znovu přes nabídku „*View*“ a podnabídku „*Options*“ volit počet zobrazených historických hodnot, počet zobrazených hodnot zpětné predikce a zvolit zobrazení pásma pravděpodobnosti. V této nabídce má navíc uživatel možnost zobrazit grafický průběh venkovní teploty.

6.2 Konkrétní výsledky predikce


V úzké spolupráci se společností MST, a.s. – Teplárnou Olomouc a Teplárnou Otrokovice, a.s. byla naměřena konkrétní reálná data odběrů tepla (lokalita Olomoucka a Zlínska) a také hodnoty venkovní teploty k těmto odběrům. Na základě těchto dat byla provedena spousta výpočtů předpovědi DDDT pomocí metody dvojí filtrace a metody superpozice modelů. Obě metody byly doplněny o zahrnutí nepravidelných kalendářních vlivů a také o zahrnutí vlivu venkovní teplota. Ukázka konkrétních výsledků těchto výpočtů je detailně znázorněna na následujících obrázcích (grafická i tabulková podoba).

6.2.1 Konkrétní výsledky predikce DDDT metodou dvojí filtrace


V první části se zaměříme na výsledky předpovědi získané pomocí metody dvojí filtrace. Výsledky jsou zobrazeny jak v podobě grafického průběhu tak i v podobě konkrétních hodnot, které jsou při předpovědi sledovány. Pro názornost a průhlednost byl průběh minulých hodnot omezen na 3 dny. Jsou zde vyobrazeny výsledky pro obě uvažované lokality (lokalita Olomoucka, lokalita Zlínska). Pro lokalitu Olomoucka byly výsledky získány pro vzorkovací periodu 1 hodina (viz Obr. 6.9), pro periodu 30 minut (viz Obr. 6.10) a navíc pro periodu 30 minut s použitím vyhlazení časové řady podle návodu z kapitoly 5.2.1 (viz Obr. 6.11). Výsledky v podobě konkrétních hodnot, které jsou při výpočtu predikce sledovány jsou pro předchozí tři případy přehledně zobrazeny na Obr. 6.12.



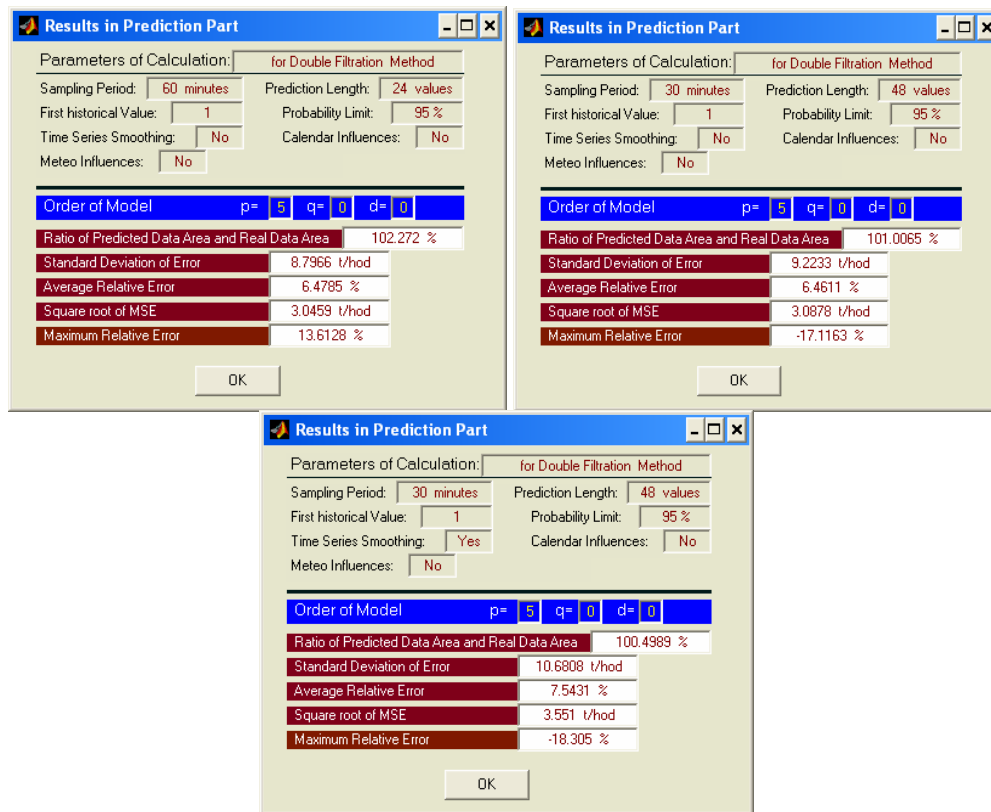
Obr. 6.9: Grafické zobrazení průběhu predikce metodou dvoji filtrace pro vzorkovací periodu 1 hodina (lokalita Olomoucka)



Obr. 6.10: Grafické zobrazení průběhu predikce metodou dvoji filtrace pro vzorkovací periodu 30 minut (lokalita Olomoucka)




Obr. 6.11: Grafické zobrazení průběhu predikce metodou dvoji filtrace pro vzorkovací periodu 30 minut s použitím vyhlazení časové řady (lokality Olomoucka)




Obr. 6.12: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody dvoji filtrace (lokality Olomoucka)

Pro lokalitu Zlínka jsou zobrazeny výsledky jen pro vzorkovací periodu 1 hodina (viz Obr. 6.13), protože data nebyla získána s menší vzorkovací periodou. Na Obr. 6.14 jsou opět vidět výsledky předpovědi při použití vyhlazení časové řady podle návodu z kapitoly 5.2.1.



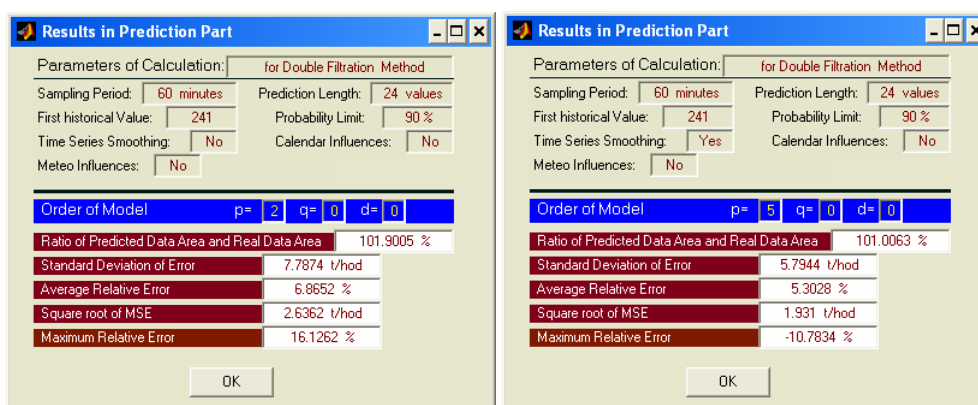
Obr. 6.13: Grafické zobrazení průběhu predikce metodou dvojí filtrace pro vzorkovací periodu 1 hodina (lokalita Zlínka)



Obr. 6.14: Grafické zobrazení průběhu predikce metodou dvojí filtrace pro vzorkovací periodu 1 hodina s použitím vyhlazení časové řady (lokalita Zlínka)

Z těchto výsledků lze vypožorovat že v tomto případě vyhlazení časové řady přineslo zlepšení předpovědi, protože byly odstraněny mírné fluktuace kolem reálných


hodnot. Na Obr. 6.15 jsou pro předchozí dva případy opět přehledně zobrazeny výsledky v podobě konkrétních hodnot, které jsou při výpočtu predikce sledovány.




Obr. 6.15: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody dvojí filtrace (lokalita Zlínka)

6.2.2 Konkrétní výsledky predikce DDDT metodou superpozice modelů


V další části se zaměříme na výsledky předpovědi získané pomocí metody superpozice modelů. Výsledky jsou opět zobrazeny jak v podobě grafického průběhu tak i v podobě konkrétních hodnot, které jsou při předpovědi sledovány. Opět jsou prezentovány výsledky pro obě uvažované lokality (lokalita Olomoucka, lokalita Zlínka). Pro lokalitu Olomoucka jsou výsledky pro vzorkovací periodu 1 hodina zachyceny na Obr. 6.16, pro periodu 30 minut na Obr. 6.17 a pro periodu 30 minut s použitím vyhlazení časové řady podle návodu z kapitoly 5.2.1 na Obr. 6.18. Výsledky v podobě konkrétních hodnot, které jsou při výpočtu predikce sledovány jsou pro předchozí tři případy přehledně zobrazeny na Obr. 6.19.



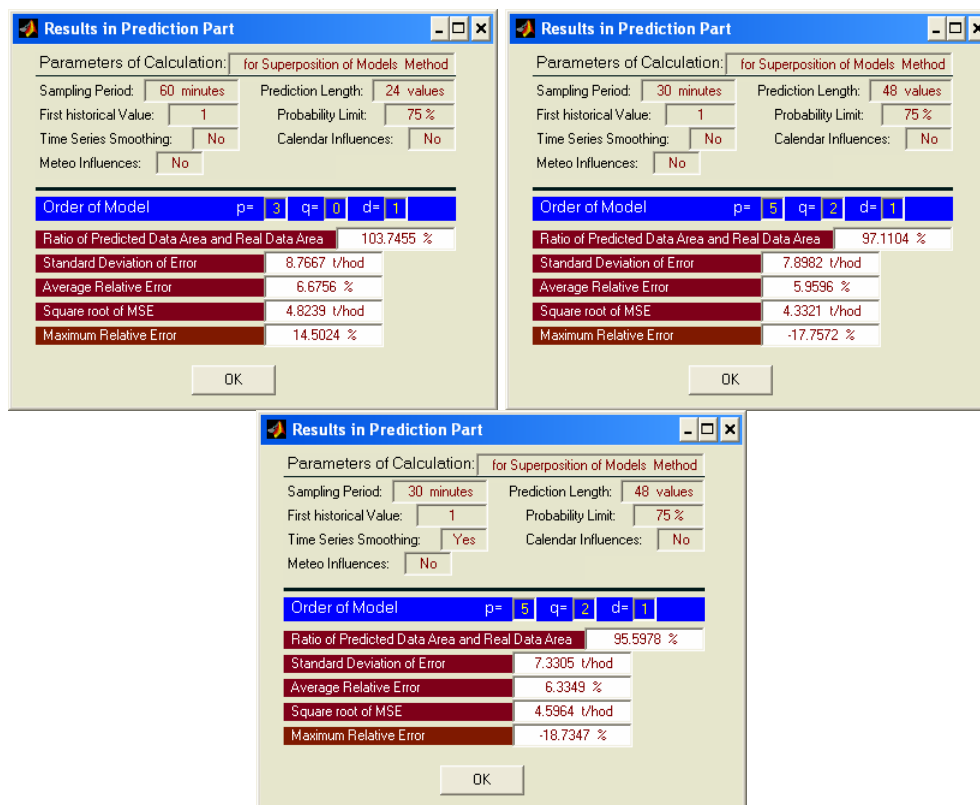
Obr. 6.16: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 1 hodina (lokalita Olomoucka)



Obr. 6.17: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 30 minut (lokalita Olomoucka)




Obr. 6.18: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 30 minut s použitím vyhlazení časové řady (lokality Olomoucka)




Obr. 6.19: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody superpozice modelů (lokality Olomoucka)

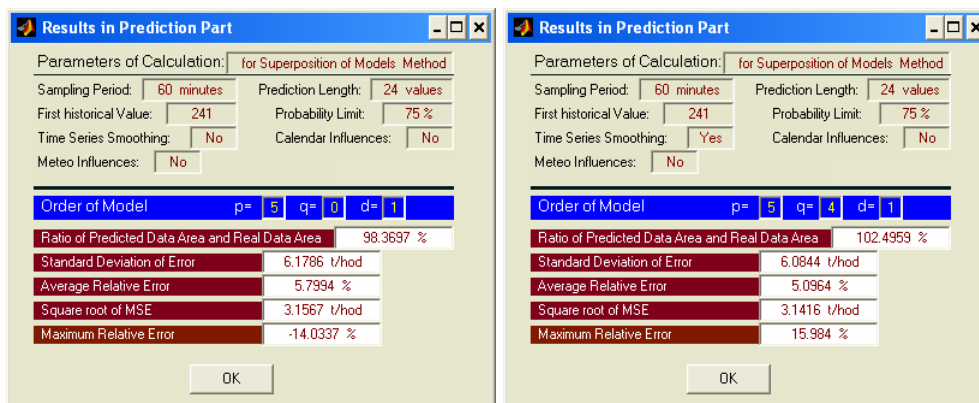
Pro lokalitu Zlínka jsou zobrazeny výsledky opět jen pro vzorkovací periodu 1 hodina (viz Obr. 6.20). Na Obr. 6.21 jsou pak prezentovány výsledky předpovědi při použití vyhlazení časové řady podle návodu z kapitoly 5.2.1. Na Obr. 6.22 jsou pro předchozí dva případy opět přehledně zobrazeny výsledky v podobě konkrétních hodnot, které jsou při výpočtu predikce sledovány



Obr. 6.20: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 1 hodina (lokalita Zlínka)




Obr. 6.21: Grafické zobrazení průběhu predikce metodou superpozice modelů pro vzorkovací periodu 1 hodina s použitím vyhlazení časové řady (lokalita Zlínka)




Obr. 6.22: Výsledky ve formě konkrétních hodnot pro předchozí předpovědi podle metody superpozice modelů (lokality Zlínka)

6.2.3 Konkrétní výsledky predikce DDDT se zahrnutím nepravidelných kalendářních vlivů

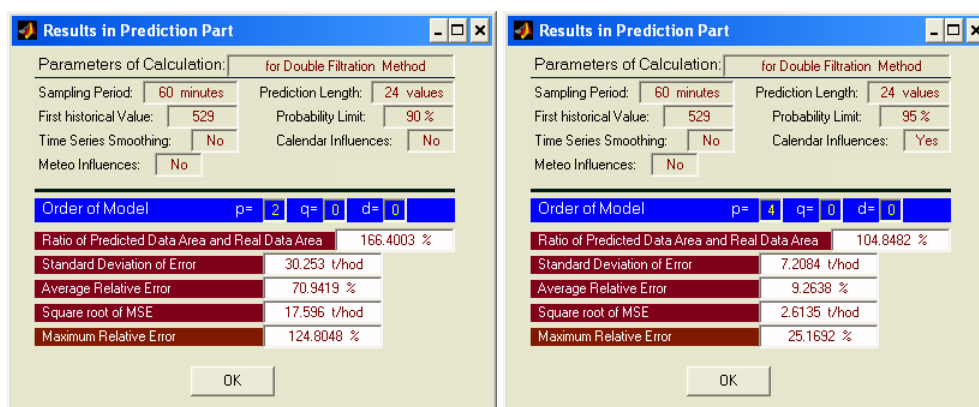
Výpočet předpovědi průběhu DDDT se zahrnutím nepravidelných kalendářních vlivů je demonstrován na časové řadě reálných odběrů tepla ve Zlínské lokalitě. V našem případě jsme se při výpočtu zaměřili na předpověď průběhu DDDT na den pondělí 28.10. 1996, který byl státem uznávaným svátkem. Ukázka výsledků předpovědi průběhu DDDT na tento den je detailně znázorněna na Obr. 6.23 a Obr. 6.24. Na Obr. 6.25 jsou opět přehledně zobrazeny výsledky v podobě konkrétních hodnot, které jsou při výpočtu predikce sledovány.



Obr. 6.23: Grafické zobrazení průběhu predikce DDDT na den 28.10.1996 bez zahrnutí nepravidelných kalendářních vlivů (lokality Zlínka)

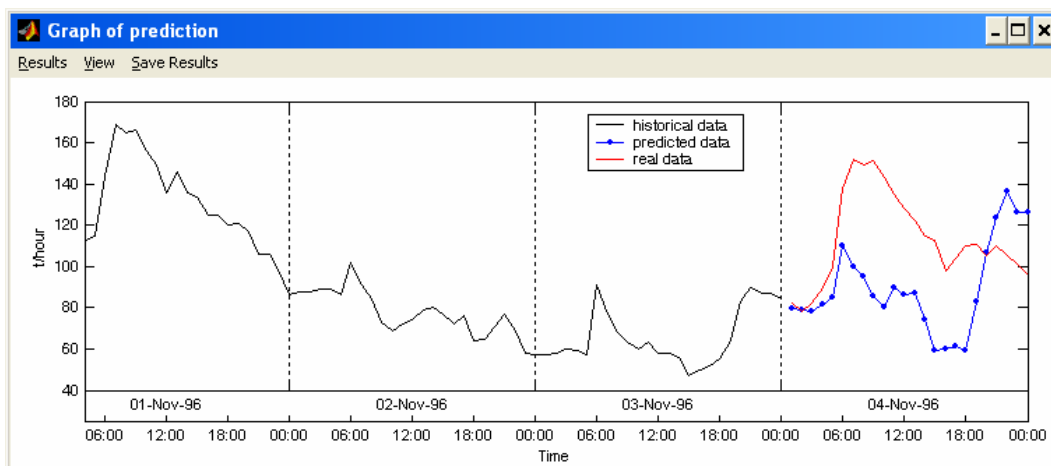


Obr. 6.24: Grafické zobrazení průběhu predikce DDDT na den 28.10.1996 se zahrnutím nepravidelných kalendářních vlivů (lokalita Zlínska)




Obr. 6.25: Výsledky ve formě konkrétních hodnot pro předpovědi na den 28.10.1996 bez zahrnutí resp. se zahrnutím nepravidelných kalendářních vlivů

Pro obě předpovědi bylo použito metody dvojí filtrace, která se v tomto případě chová daleko stabilněji. Jak již bylo řečeno v části 5.5 nezahrnutí těchto nepravidelných kalendářních vlivů nám ovlivní i průběh predikce v dalších dnech. Názorná ukázka se vztahuje k předpovědi na následující pondělí po 28.10.1996, tzn. na den 4.11.1996. Průběh predikce DDDT bez zahrnutí resp. se zahrnutím těchto vlivů je zobrazen na Obr. 6.26 a Obr. 6.27.

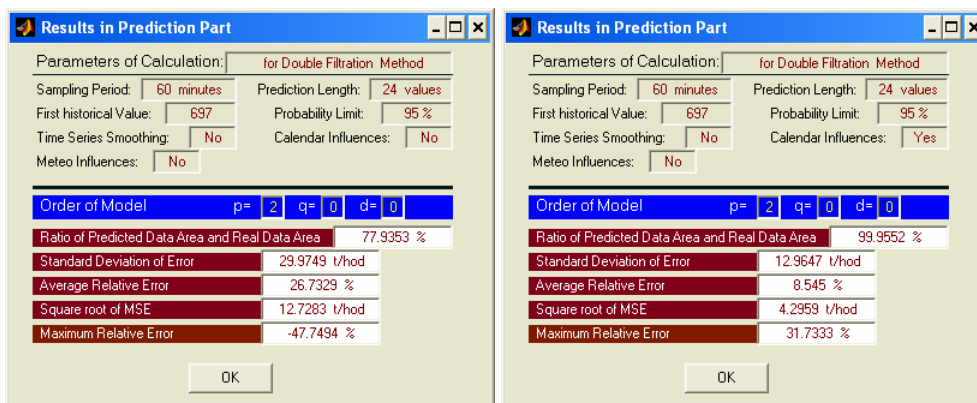


Obr. 6.26: Grafické zobrazení průběhu predikce DDDT na následující pondělí tj.4.11.1996 bez zahrnutí nepravidelných kalendářních vlivů



Obr. 6.27: Grafické zobrazení průběhu predikce DDDT na následující pondělí tj.4.11.1996 se zahrnutím nepravidelných kalendářních vlivů

Z průběhů je jasně vidět vliv zahrnutí nepravidelných kalendářních vlivů na přesnost předpovědi DDDT. Z následujícího Obr. 6.28 je možné si udělat představu o přesnosti predikce předchozích výpočtů v podobě konkrétních hodnot, které jsou při výpočtu predikce sledovány.




Obr. 6.28: Výsledky ve formě konkrétních hodnot pro předpovědi na následující pondělí tj. den 4.11.1996 bez zahrnutí resp. se zahrnutím nepravidelných kalendářních vlivů


6.2.4 Konkrétní výsledky predikce DDDT se zahrnutím vlivu venkovní teploty

Pro výpočet předpovědi průběhu DDDT se zahrnutím vlivu venkovní teploty je třeba k časové řadě reálných odběrů tepla získat časovou řadu hodnot venkovní teploty. Tyto řady byly opět získány na základě úzké spolupráce se společností Teplárna Otrokovice, a.s., respektive MST, a.s.–Teplárnou Olomouc.


Ukázka výsledků se zahrnutím vlivů venkovní teploty bude prezentována jak pro lokalitu Olomoucka tak i pro lokalitu Zlínka. V prvním případě jsme se zaměřili na předpověď průběhu DDDT v lokalitě Olomoucka na dny pondělí 23.11.1998 a úterý 24.11.1998. V těchto dnech zejména pak v úterý došlo k oteplení vzhledem k předchozím dnům až o 5°C. Tato situace je názorně vidět v grafu na Obr. 6.29. Průběh predikce DDDT bez zahrnutí vlivu venkovní teploty je zachycen na Obr. 6.30 a výsledky předpovědi se zahrnutím těchto vlivů jsou pak demonstrovány v grafech na Obr. 6.31 resp. Obr. 6.32. Vše je také doloženo výpisem výsledků ve formě konkrétních hodnot, které jsou při výpočtu predikce sledovány (viz Obr. 6.33).




Obr. 6.29: Grafické zobrazení průběhu venkovní teploty v období 20.11.-24.11.1998 (lokality Olomoucka, vzorkovací perioda 30 minut)



Obr. 6.30: Grafické zobrazení průběhu predikce DDDT bez zahrnutí vlivu venkovní teploty na pondělí 23.11.1998 a úterý 24.11.1998 (lokality Olomoucka, vzorkovací perioda 30 minut)

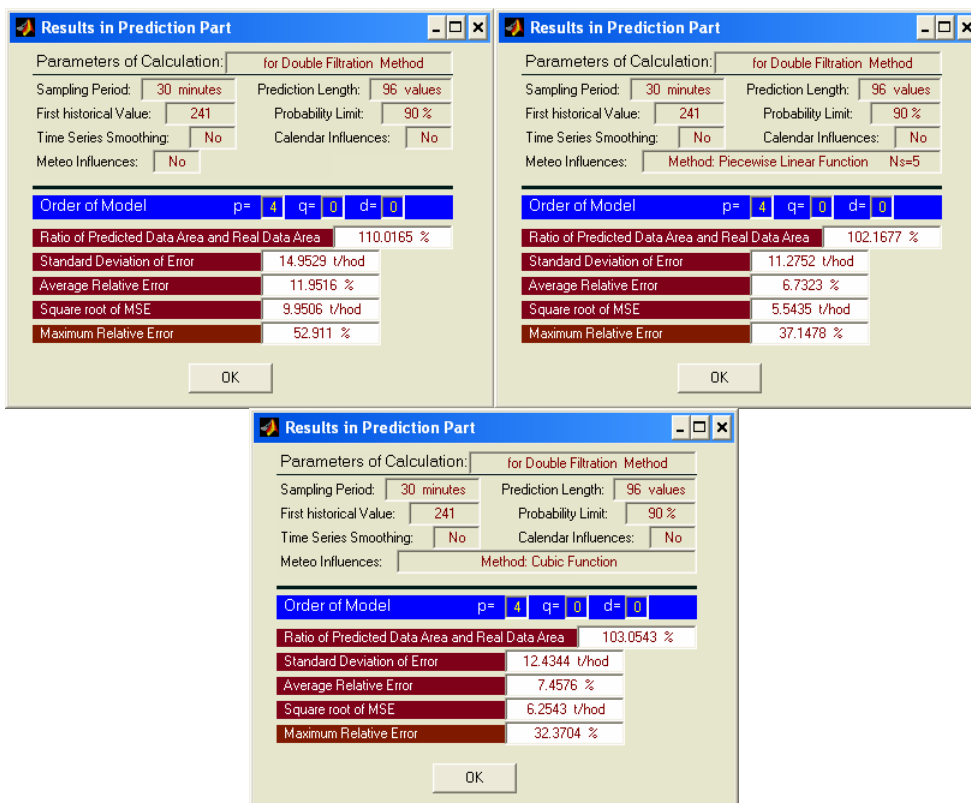


Obr. 6.31: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na pondělí 23.11.1998 a úterý 24.11.1998 použitím topné charakteristiky ve tvaru po částech se měnící lineární funkce (lokality Olomoucka, vzorkovací perioda 30 minut)




Obr. 6.32: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na pondělí 23.11.1998 a úterý 24.11.1998 použitím topné charakteristiky ve tvaru kubické křivky (lokality Olomoucka, vzorkovací perioda 30 minut)

Z grafických průběhů na předchozích obrázcích je zřejmé, že v tomto případě došlo ke zpřesnění průběhu predikce DDDT zahrnutím vlivu venkovní teploty a to jak v případě použití topné charakteristiky ve tvaru po částech lineární funkce nebo ve tvaru kubické křivky.

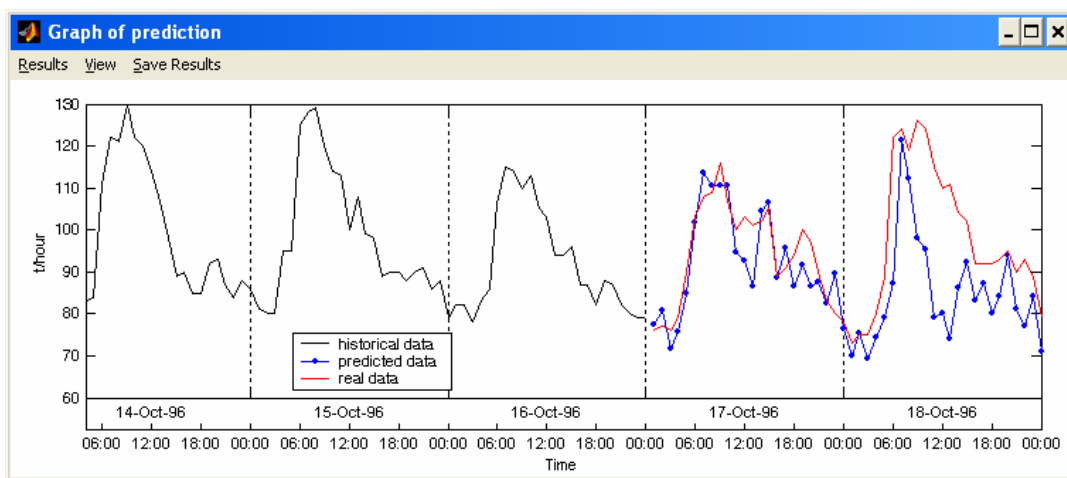


Obr. 6.33: Výsledky ve formě konkrétních hodnot pro předpovědi DDDT na pondělí 23.11.1998 a úterý 24.11.1998 bez zahrnutí resp. se zahrnutím vlivu venkovní teploty (lokality Olomoucka)


V druhém případě jsme se zaměřili na předpověď průběhu DDDT v lokalitě Zlínka na dny čtvrtek 17.10.1996 a pátek 18.10.1996. V těchto dnech zejména pak v pátek došlo k ochlazení vzhledem k předchozím dnům až o 6°C. Tato situace je názorně vidět v grafu na Obr. 6.34. Průběh predikce DDDT bez zahrnutí vlivu venkovní teploty je zachycen na Obr. 6.35. Výsledek předpovědi se zahrnutím těchto vlivů použitím topné charakteristiky ve tvaru po částech se měnící lineární funkce je pak demonstrován v grafu na Obr. 6.36. Na Obr. 6.37. je pak zobrazen průběh předpovědi DDDT se zahrnutím vlivu venkovní teploty použitím topné charakteristiky ve tvaru kubické křivky. V tomto případě byl výpočet prováděn s vyrovnáním (vyhlazením) časové řady. Vše je také doloženo výpisem výsledků ve formě konkrétních hodnot, které jsou při výpočtu predikce sledovány (viz Obr. 6.38).



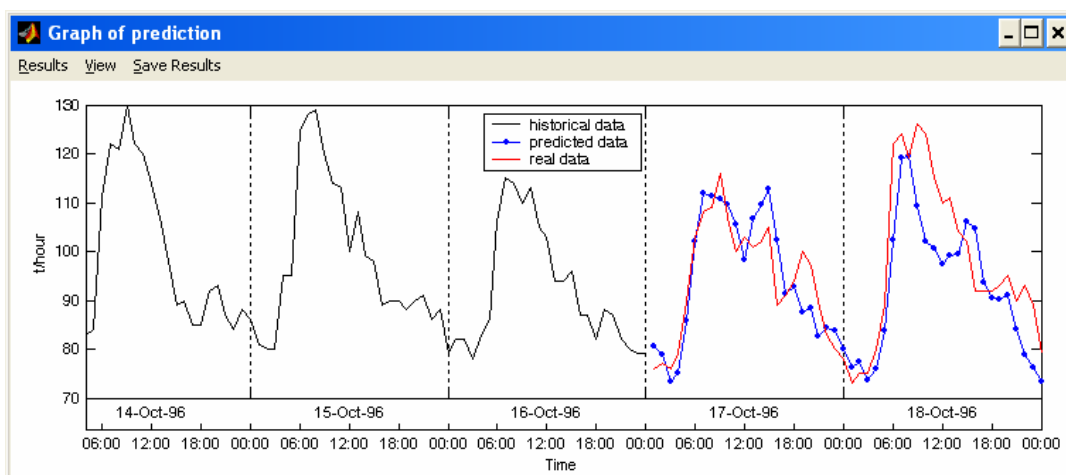
Obr. 6.34: Grafické zobrazení průběhu venkovní teploty v období 14.10.-18.10.1996 (lokality Zlínka, vzorkovací perioda 1 hodina)



Obr. 6.35: Grafické zobrazení průběhu predikce DDDT bez zahrnutí vlivu venkovní teploty na čtvrtek 17.10.1996 a pátek 18.10.1996 (lokality Zlínka, vzorkovací perioda 1 hodina)



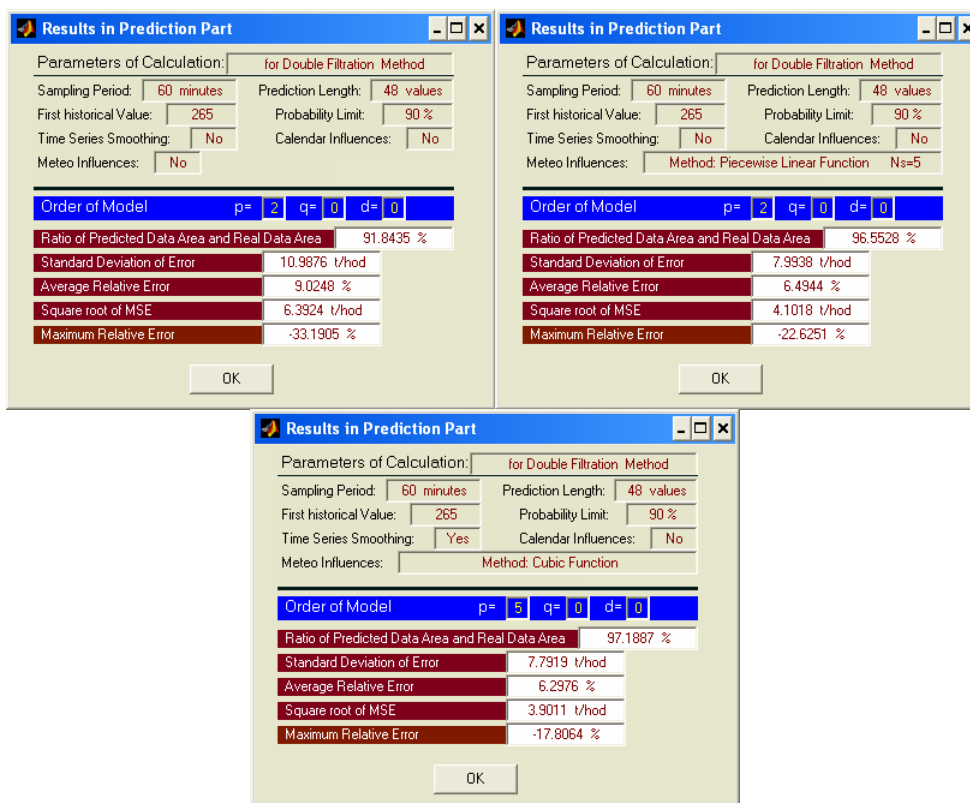
Obr. 6.36: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na čtvrtek 17.10.1996 a pátek 18.10.1996 použitím topné charakteristiky ve tvaru po částech se měnící lineární funkce (lokality Zlínka, vzorkovací perioda 1 hodina)



Obr. 6.37: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na čtvrtek 17.10.1996 a pátek 18.10.1996 použitím topné charakteristiky ve tvaru kubické křivky s vyrovnáním časové řady (lokality Zlínka, vzorkovací perioda 1 hodina)

Z grafických průběhů na předchozích obrázcích je zřejmé, že v případě zahrnutí vlivu venkovní teploty do výpočtu předpovědi DDDT došlo ke zpřesnění průběhu predikce a to jak v případě použití topné charakteristiky ve tvaru po částech lineární funkce nebo ve tvaru kubické křivky. Vyrovnání časové řady při použití topné charakteristiky ve tvaru


kubické křivky bylo zvoleno jen pro ukázkou, že všechny možnosti, které nabízí tento program lze při výpočtu kombinovat




Obr. 6.38: Výsledky ve formě konkrétních hodnot pro předpovědi DDDT na dny čtvrtek 17.10.1996 a pátek 18.10.1996 bez zahrnutí resp. se zahrnutím vlivu venkovní teploty (lokality Zlínka)

Na datech z lokality Zlínka si budeme demonstrovat ještě jeden příklad výpočtu předpovědi DDDT se zahrnutím vlivu venkovní teploty. Konkrétně se jedná o predikci průběhu DDDT na sobotu 2.11.1996. V tento den došlo k znatelnému oteplení vzhledem k předchozím dnům. Tato situace je názorně vidět v grafu na Obr. 6.39. Tento případ je zajímavý tím, že do výpočtu jsou zahrnuty jak vlivy meteorologické tak i vlivy kalendářní, protože minulé hodnoty, ze kterých je predikce počítána, obsahují den pracovního klidu (svátek 28.10.1996). Průběh predikce DDDT bez zahrnutí vlivu venkovní teploty je zachycen na Obr. 6.40. Výsledek předpovědi se zahrnutím těchto vlivů použitím topné charakteristiky ve tvaru kubické křivky je pak demonstrován v grafu na Obr. 6.41. Výpis


výsledků ve formě konkrétních hodnot, které jsou při výpočtu predikce sledovány je názorně zobrazen na Obr. 6.42.



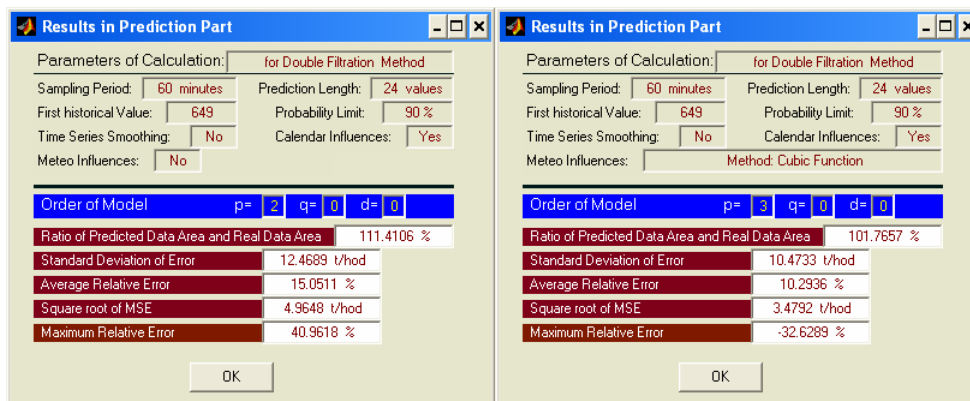
Obr. 6.39: Grafické zobrazení průběhu venkovní teploty v období 30.10.-2.11.1996 (lokalita Zlínska, vzorkovací perioda 1 hodina)



Obr. 6.40: Grafické zobrazení průběhu predikce DDDT bez zahrnutí vlivu venkovní teploty na sobotu 2.11.1996 (lokalita Zlínska, vz. perioda 1 hodina)



Obr. 6.41: Grafické zobrazení průběhu predikce DDDT se zahrnutím vlivu venkovní teploty na sobotu 2.11.1996 použitím topné charakteristiky ve tvaru kubické křivky (lokality Zlínka, vzorkovací perioda 1 hodina)



Obr. 6.42: Výsledky ve formě konkrétních hodnot pro předpovědi DDDT na sobotu 2.11.1996 bez zahrnutí resp. se zahrnutím vlivu venkovní teploty (lokality Zlínka)

7 VYUŽITELNOST VÝSLEDKŮ ŘEŠENÍ

Jak již bylo uvedeno v úvodu této práce, důkladná analýza časových řad a následná předpověď jejich budoucího chování vede ke zlepšení úrovně řízení technologického procesu. Aplikaci takovéto předpovědi je možno najít i při řízení v soustavě centralizovaného zásobování teplem (SCZT). SCZT má zajistit všem odběratelům tepla dodávku tepelné energie v množství, podle jejich časově proměnných potřeb. Dodávka energie musí vždy vyhovovat předepsaným ukazatelům jakosti, v případě horkovodu jde o dodržení předepsané teploty horké vody v přírodním potrubí.

Nepostradatelnou součástí filosofie způsobu řízení v SCZT je tedy předpověď průběhu denního diagramu dodávky tepla v dané lokalitě. Tyto průběhy mají zásadní důležitost při technických a ekonomických úvahách, zejména pak pro krátkodobé a dlouhodobé plánování výroby tepla. Podle časového průběhu potřeby tepla lze posuzovat například otázku špičkových zdrojů a zejména otázku optimálního rozdělování zatížení mezi spolupracující výrobní zdroje a výrobní jednotky uvnitř těchto zdrojů.

Pokud tedy shrneme předchozí úvahy, můžeme předpověď průběhu DDDT využít při řízení v SCZT, jmenovitě při řízení tepelného výkonu horkovodu ve dvou rovinách:

1. Předpověď je využita pro plynulé určování potřebného tepelného výkonu horkovodu v časovém předstihu, který je závislý na dopravním zpoždění (a to v rozsahu např. 2-16 hodin) v závislosti na vzdálenosti zdrojů tepla od spotřebitelů, což je pro každou lokalitu rozdílné. Eliminaci tohoto dopravního zpoždění umožňuje „*kvalitativně-quantitativní způsob řízení tepelného výkonu horkovodu – systém Balátě*“, kde právě předpověď časové řady průběhu části DDDT je nezbytnou součástí tohoto řešení.
2. Je prováděna predikce celého denního diagramu dodávky tepla (DDDT) SCZT. Tato předpověď je určena pro účel řízení výroby tepla a tedy *optimálního rozdělování zatížení mezi spolupracující výrobní zdroje a v nich výrobních jednotek* (teplárny, výtopny, spalovny, dálkové napáječe). Cílem předpovědi je krátkodobá příprava výroby v časovém horizontu 24 hodin, kdy určíme minimální spotřebu paliva a energie, což přispívá k ekonomii a ekologii provozu.

7.1 Kvalitativně – kvantitativní způsob řízení tepelného výkonu horkovodu

Algoritmus tzv. kvalitativně-kvantitativního způsobu řízení s využitím predikce průběhu denního diagramu dodávky tepla v horkovodních systémech centralizovaného zásobování teplem umožňuje eliminovat vliv dopravního zpoždění mezi zdrojem tepla a odběru tepla relativně soustředěných spotřebitelů. Dopravní zpoždění je závislé na rychlosti proudění teplotnosného média (horké vody) a na délce potrubí napáječe. *Nový způsob řízení výkonu horkovodu spočívá v současném a průběžném působení dvou akčních veličin ovlivňujících přenášený tepelný výkon a ve využívání předpovědi požadovaného tepelného výkonu v dané lokalitě.* Nově navržená metoda řízení byla uvažována pro konkrétní případ, kdy dopravní zpoždění bylo předpokládáno v rozsahu od šesti do dvanácti hodin v závislosti na odebíraném tepelném výkonu všech spotřebitelů.

V současné době jsou zpracovány následující tři způsoby aplikace kvalitativně-kvantitativního způsobu řízení výkonu horkovodu a to podle technologického zařízení zdroje tepla:

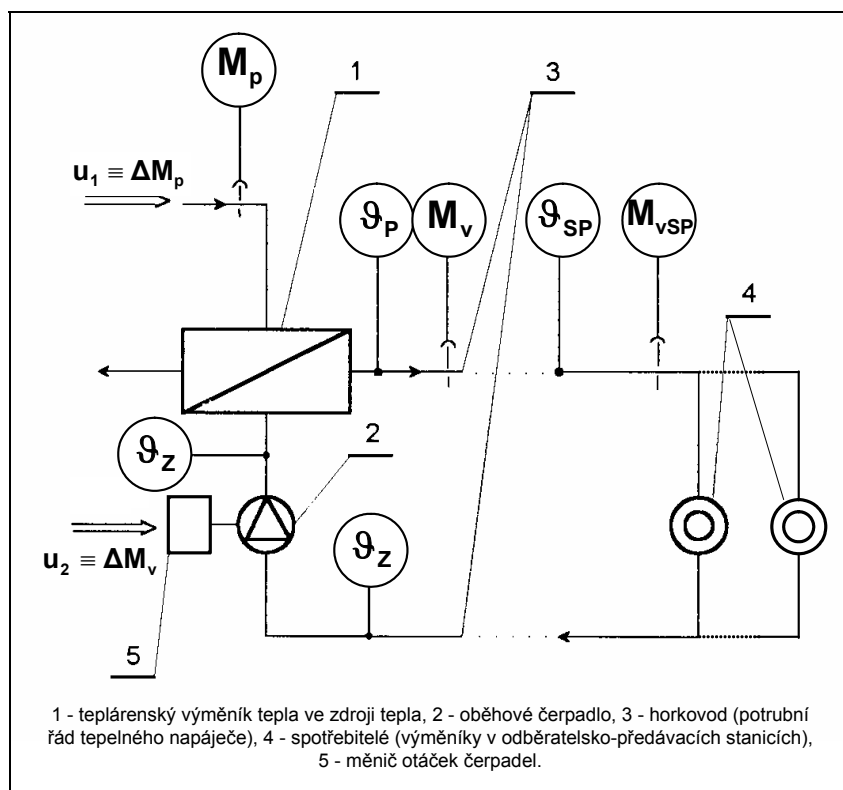
1. Základní způsob při teplárenském způsobu výroby tepla - princip: **Kvalitativně-kvantitativní způsob řízení tepelného výkonu horkovodu s využitím predikce průběhu denního diagramu dodávky tepla v systémech centralizovaného zásobování teplem.**
2. Modifikace základního způsobu: **Přizpůsobení kvalitativně-kvantitativního způsobu řízení dodávky tepla horkovodem pro případ využití části potrubního řádu pro akumulaci tepla.**

Způsob řízení je vytvořen pro případ, kdy je možné část potrubního řádu napáječe využít pro akumulaci tepla a umožňuje eliminovat vliv dopravního zpoždění mezi zdrojem tepla a relativně soustředěným odběrem tepla všemi spotřebiteli. Umožňuje při kombinované výrobě tepla a elektrické energie využít akumulaci tepla pro dodávku tepla pro teplárenské účely mimo časového intervalu trvání špiček dodávky elektrické energie.

3. Modifikace, kdy zdrojem tepla jsou horkovodní kotle: **Algoritmus kvalitativně- kvantitativního způsobu řízení výkonu s horkovodními kotli jako zdroji tepla.**

7.1.1 Kvalitativně- kvantitativní způsob řízení tepelného výkonu horkovodu s využitím predikce průběhu denního diagramu dodávky tepla v systémech centralizovaného zásobování teplem.

Je vytvořen pro případ dodávky tepla v teplotěnském výměníku ve zdroji tepla. Technologické schéma je uvedeno na Obr. 7.1.



Obr. 7.1: Principiální schéma horkovodu

Použitá označení v Obr. 7.1:

$\theta_z(^{\circ}\text{C})$ je teplota ve zpětné větvi horkovodu, $\theta_p(^{\circ}\text{C})$ - teplota v přívodní větvi horkovodu, $\theta_{sp}(^{\circ}\text{C})$ - teplota horké vody v přívodní větvi v místě spotřebitelů, $M_v(\text{kg}\cdot\text{s}^{-1})$ - hmotnostní průtok teplotěnského média na výstupu z výměníku, $M_{vsp}(\text{kg}\cdot\text{s}^{-1})$ - hmotnostní průtok teplotěnského média v přívodní v místě spotřebitelů, $M_p(\text{kg}\cdot\text{s}^{-1})$ - hmotnostní průtok páry na vstupu do teplotěnského výměníku, $u_1(-)$ - akční veličina 1 (změna hmotnostního průtoku páry, $u_2(-)$ - akční veličina 2 (změna otáček oběhových čerpadel).

Tento způsob řízení umožňuje eliminovat vliv dopravního zpoždění mezi zdrojem tepla a relativně soustředěným odběrem tepla všemi spotřebiteli.

Současný běžný způsob řízení tepelného výkonu dodávky tepla horkovodem využívá obvykle závislosti na teplotě vody v přívodním potrubí tepelného napáječe nebo také ještě závislosti na teplotě venkovního vzduchu.

Pro řízení tepelného výkonu horkovodu ze zdroje tepla jsou k dispozici dvě akční veličiny:

- změna rozdílu teplot vody v přívodním a vratném potrubí horkovodu v praxi realizovaná změnou tepelného příkonu na vstupu do teplotěnského výměníku, *tzv. kvalitativní způsob řízení tepelného výkonu;*
- změna hmotnostního toku horké vody změnou otáček oběhového čerpadla, *tzv. kvantitativní způsob řízení tepelného výkonu.*

Uvedené akční veličiny bývají obvykle používány jako samostatně působící, a to pouze jedna z nich. Pokud se používají obě, jednalo se o případ, kdy kvalitativní způsob řízení byl hlavním způsobem řízení a kvantitativního způsobu se využívalo spouštěním a zastavováním chodu čerpadel s různým dopravovaným hmotnostním tokem. Těchto kvantitativních změn se využívalo jednorázově při změnách ročních období (letní, přechodové, zimní). Obvykle bylo pro tento účel použito cirkulačních čerpadel dvou nebo tří velikostí.

Nevýhodou popsaných způsobů řízení je skutečnost, že úplně nezahrnují dynamické vlastnosti regulované soustavy (řízeného systému). Dopravní zpoždění v přívodní větvi tepelného příváděče a zpoždění setrvačných členů teplotěnského výměníku zůstávají opomenuty. Jestliže se změní výkon odebíraný v některém místě horkovodní sítě, potom odpovídající výkon zdrojů (výroby) řízený klasickým kvalitativním způsobem se sice přizpůsobí se značným zpožděním, i když samoreglativně dojde ke změně hmotnostního toku horké vody vlivem autoreglativních vlastností statické charakteristiky dopravního čerpadla zapříčiněné změnou pracovního bodu čerpadla. Změna odběru tepelného výkonu se uskuteční působením autonomních regulátorů teploty v sekundárních

sítích odběratelsko-předávacích stanic. Vznikne tím nesplnění některého z požadavků na předepsané ukazatele jakosti teplotního média.

Algoritmus pro takový způsob řízení byl navržen a simulačně prověřován. Byl nazván *kvalitativně-kvantitativním způsobem řízení tepelného výkonu horkovodu s využitím předpovědi průběhu denního diagramu dodávky tepla*.

Algoritmus výše popsaného a nazvaného způsobu řízení, tj. použitím dvou akčních veličin a to samostatně pro kvalitativní způsob a kvantitativní způsob řízení, je zobrazen na Obr. 7.2.

Posloupnost kvalitativního způsobu řízení je následující:

- změření hmotnostního toku teplotního média (horké vody) (krok 1),
- určení dopravního zpoždění (krok 2),
- určení doby, za kterou se působení (zásah) kvalitativního způsobu řízení projeví u spotřebitelů (krok 3),
- výpočet tepelného výkonu, který je nastavován kvalitativním způsobem řízení, zahrnující i korekci tepelného obsahu v přívodní větvi napáječe (krok 4), (krok 5),
- přeměna řídicího signálu na akční veličinu, tj. na polohu regulačního ventilu přívodní páry na vstupu do teplotrenského výměníku (krok 6).

Posloupnost kvantitativního způsobu řízení je tato:

- změření skutečných (aktuálních) hodnot parametrů potřebných pro další výpočet (krok 1),
- výpočet skutečného odebíraného tepelného výkonu v místě spotřebitelů (krok 2),
- výpočet odchylky kvalitativního způsobu řízení a skutečného odebíraného (aktuálního) výkonu u spotřebitelů - (krok 3)
- výpočet kvantitativní korekce tepelného výkonu (krok 4),
- přeměna řídicího signálu na akční veličinu, tj. na hodnotu otáček oběhového (cirkulačního) čerpadla (krok 5).

KVANTITATIVNÍ ČÁST ŘÍZENÍ

1 Výpočet $P_{T,T}^P$

$$P_{T,T}^P = M_{v,RT}^s \cdot c \cdot \Delta\theta_T^P$$

$$\Delta\theta_T^P = \frac{P_{T,T}^P}{M_{v,RT}^s \cdot c}$$

$$\Delta\theta_T^{P,Q} = \frac{P_{T,T}^P + \frac{\Delta Q}{T_x}}{M_{v,RT}^s \cdot c}$$

2 Určení dopravního zpoždění $T_d^P = f(M_{v,RT}^s)$

3 Určení času T

$$T = RT + T_d^P + T_{přech}$$

4 Předpokládaný průběh DDDT $P_T^P = f(t)$

5 V předstihu $T_d + T_{přech}$ provede zásah regulačním ventilem topné pátý. Nastaví se: $\Delta\theta_T^{P,Q}$ Resp. $\Delta\theta_T^P$

PREDIKCE DDDT

1 Výpočet $P_{T,T}^S$

$$P_{T,T}^S = M_{v,RT}^s \cdot c \cdot \Delta\theta_T^S$$

$$\Delta\theta_T^S = \frac{P_{T,T}^S}{M_{v,RT}^s \cdot c}$$

2 Výpočet odchylky ΔP_T

$$\Delta P_T = P_{T,T}^P - P_{T,T}^S$$

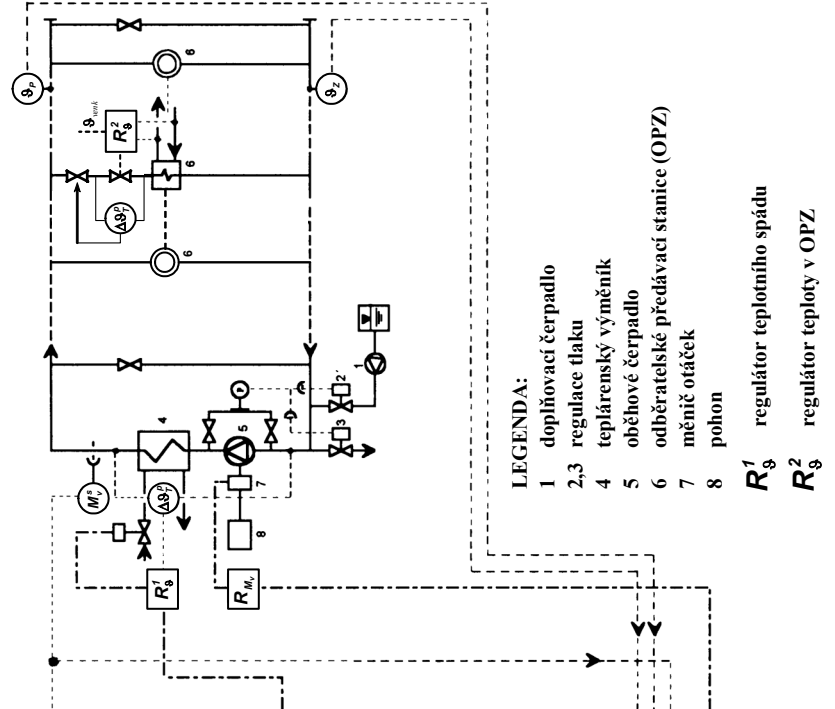
$$\Delta P_{T,T} = M_{v,RT}^s \cdot c \cdot \Delta\theta_T^S - M_{v,T}^s \cdot c \cdot \Delta\theta_T^P$$

$$\Delta P_{T,T} = c \cdot (M_{v,RT}^s \cdot \Delta\theta_T^S - M_{v,T}^s \cdot \Delta\theta_T^P)$$

3 Kvantitativní korekce

$$\Delta M_{v,T}^s = \frac{\Delta P_T}{c \cdot \Delta\theta_T^S}$$

4 Provede se zásah pro změnu hmotnostního průtoku horké vody $\Delta M_{v,T}^s$



- LEGENDA:**
- 1 doplňovací čerpadlo
 - 2,3 regulace tlaku
 - 4 teplotěnský výměník
 - 5 oběhové čerpadlo
 - 6 odběratelské předávací stanice (OPZ)
 - 7 měnič otáček
 - 8 pohon
- R_θ^1 regulátor teplotního spádu
 R_θ^2 regulátor teploty v OPZ
 R_{M_v} regulátor hmotnostního průtoku

Obr. 7.2: Algorithmus kvalitativně – kvantitativního způsobu řízení dodávky tepla horkovodem

Legenda k Obr. 7.2:

c - měrná tepelná kapacita, l - délka přívodní větve tepelného napáječe, RT - reálný čas (čas, ve kterém působí akční veličina kvalitativního způsobu řízení na teplotěnském výměníku), S - průřez přívodní větve napáječe, T - čas, ve kterém se projeví působení akční veličiny kvalitativního způsobu řízení u lokálně soustředěných spotřebitelů, T_d - dopravní zpoždění, T_d^p - předpokládané dopravní zpoždění, $T_{př}$ - časový předstih, $T_{přech}$ - doba přechodu teplotěnského výměníku při působení akční veličiny, T_{VZ} - perioda vzorkování (asi 15 minut), M_v - hmotnostní tok oběhové (cirkulační) vody, $M_{v,RT}^s$ - skutečný hmotnostní tok oběhové vody v čase RT , $M_{v,T}^s$ - skutečný hmotnostní tok oběhové vody v čase T , P_T - tepelný výkon horkovodu, P_T^p - předpokládaný tepelný výkon odečtený z predikovaného denního diagramu dodávky tepla (DDDT), $P_{T,T}^p$ - předpokládaný tepelný výkon v čase T , $P_{T,T}^s$ - skutečný změřený (vypočtený) tepelný výkon v čase T , $\mathcal{G}_{P,T}^s$ - skutečná teplota v přívodní větvi napáječe u spotřebitelů v čase T , $\mathcal{G}_{Z,T}^s$ - skutečná teplota ve zpětné větvi napáječe u spotřebitelů v čase T , $\Delta P_{T,T}$ - odchylka mezi předpokládaným a skutečným odebraným tepelným výkonem v čase T , $\Delta M_{v,T}$ - kvantitativní korekce, tj. změna hmotnostního toku oběhové vody, ΔQ - změna tepelného obsahu v přívodní větvi napáječe zapříčiněná kvantitativní korekcí, $\Delta \mathcal{G}_T^s$ - skutečný teplotní spád u spotřebitelů v čase T , $\Delta \mathcal{G}_T^p$ - předpokládaný teplotní spád na teplotěnském výměníku v čase T , který se vypočte z $P_{T,T}^p$ a je akční veličinou kvalitativního způsobu řízení, $\Delta \mathcal{G}_T^{p,Q}$ - předpokládaný teplotní spád na teplotěnském výměníku v čase T zahrnující korekci tepelného obsahu v příváděcí větvi napáječe ΔQ . Toto teplo je nutné přivést, popř. o něj zmenšit přívod tepla v závislosti na smyslu (znaménka) kvantitativní korekce $\Delta M_{v,T}$, ρ_l - měrná hmotnost oběhové vody v příváděcí větvi napáječe.

7.1.2 *Algoritmus kvalitativně-quantitativního způsobu řízení výkonu horkovodu s horkovodními kotli jako zdroji tepla*

Algoritmus umožňuje způsob řízení technologického řetězce výroba – doprava+distribuce tepla v radiální nebo zokruhané horkovodní síti. Umožňuje eliminovat vliv dopravního zpoždění mezi zdrojem tepla (horkovodními roštovými kotli) a relativně soustředěným odběrem tepla všemi spotřebiteli.

Filosofie způsobu řízení využívá předpovědi (části) denního diagramu dodávky tepla v dané lokalitě (DDDT), aby při současném a průběžném působení dvou akčních veličin, **tj. kvalitativní částí řízení** (řízením teplotního spádu na vstupní a vratné větvi horkovodu resp. na horkovodním kotli) a **quantitativní částí řízení** (řízením hmotnostního

toku teplotonositele - horké vody oběhovými (dopravními) čerpadly), bylo umožněno **eliminovat dopravní zpoždění** skutečně odebíraného tepelného výkonu spotřebiteli od skutečně vyrobeného tepelného výkonu na horkovodním kotli, který byl vyroben s předstihem. Uvedený způsob řízení umožní dodávku tepelného výkonu s proměnlivou teplotou na vstupu do horkovodní sítě **v závislosti na předpověděné spotřebě tepla**.

Popsaný způsob řízení umožní s odpovídající přesností řízení technologického řetězce výroba – doprava+distribuce tepla, přičemž lze zajistit hospodárnou výrobu tepla v horkovodním kotli, resp. ve více spolupracujících kotlích v jednom zdroji tepla, případně ve spolupracujících zdrojích zapojených v zokruhované tepelné síti. Uvedený způsob řízení umožní vyhledání provozní sestavy, tj. skladby spolupracujících zdrojů a provozních variant v těchto zdrojích, tj. spolupracujících výrobních jednotek uvnitř těchto zdrojů. Určení provozní sestavy pro dílčí úseky DDDT bude podporováno využitím tzv. kritéria režimového optima, které zahrnuje nákladovost spalovaného paliva, nákladovost čerpací práce a dále i vliv na životní prostředí v souvislosti s emisemi spalovacího procesu.

Posloupnost (algoritmus) kvalitativně-quantitativního způsobu řízení výkonu horkovodu s horkovodními kotli jako zdroji tepla je popsána realizací následujících kroků (Obr. 7.3):

1. Výpočet předpovědi DDDT tj. $P_T^{p,DOD} = f(t)$,
2. Pokrytí předpověděného denního diagramu dodávky – vyrobeného tepelného výkonu $P_T^{p,DOD}$, výběr provozní sestavy spolupracujících kotelen a určení jednotlivých kotlů těchto kotelen *pro jednotlivé časové úseky denního diagramu dodávky tepla* v průběhu 24 hod. Bude využito funkčních bloků:
 - kritéria režimového optima (výběr spolupracujících zdrojů, tj. provozní sestavy),
 - optimalizace výroby tepla na jednotlivých kotlích uvnitř zdroje nelineárním programováním (výběr provozní varianty),
3. Optimalizace provozu zdrojů pro $P_{T,RT}^{p,DOD,u}$ v aktuálním časovém úseku DDDT (časový úsek je označen u)

Poznámka: V horním indexu p - značí předpověděný (predikovaný), v dolním indexu RT - značí reálný čas působení akční veličiny. Označení bylo použito z důvodu návaznosti na *základní* schéma kvalitativně-quantitativního způsobu řízení výkonu horkovodu, tj. při použití teplotního výměníku jako zdroje tepla.

4. Rozdělení zatížení mezi spolupracující zdroje

KVALITATIVNÍ ČÁST ŘÍZENÍ: $u_{1,RT}$

4.1. Nastavení výkonu zdrojů v čase RT v jednotlivých výrobních V_j (j vyjadřuje označení výroby), z nichž každá obsahuje jeden nebo více kotlů označené $K_{j,i}$

4.2. Rozdělení výkonu zdrojů na spolupracující výrobní jednotky-horkovodní kotle: $P_{T,K1,1 \rightarrow n}, P_{T,K2,1 \rightarrow n}, \dots$ Podle zjednodušených ekonomických hledisek konkrétní lokality nebo náročnějším optimalizačním výpočtem.

5. Změření (případně doplněné výpočtem) okamžité spotřeby tepla, tj. v čase T :

$\sum P_{T,T}^{spotř}$, symbol $\sum P_{T,T}^{spotř}$ značí spotřebu tepla všemi spotřebiteli v čase T

6. Stanovení pracovního bodu horkovodní sítě. Jedná se o:

- minimalizaci čerpací práce dopravních (oběhových) čerpadel,
- problém paralelní spolupráce dopravních čerpadel v jednotlivých zdrojích tepla.

7. Výpočet dopravního zpoždění v referenčním bodě horkovodní sítě $T_{d,T}^{ref}$ v čase T ,

8. Výpočet času předpovědi (tj. zpětné predikce), tj. výkonu výrobních jednotek v čase RT , jedná se o čas, o který je nutné dříve měnit akční veličinu výkonu kotlů, aby se změna tepelného výkonu horkovodního kotle projevila v čase T ,

9. KVANTITATIVNÍ ČÁST ŘÍZENÍ: $u_{2,T}$

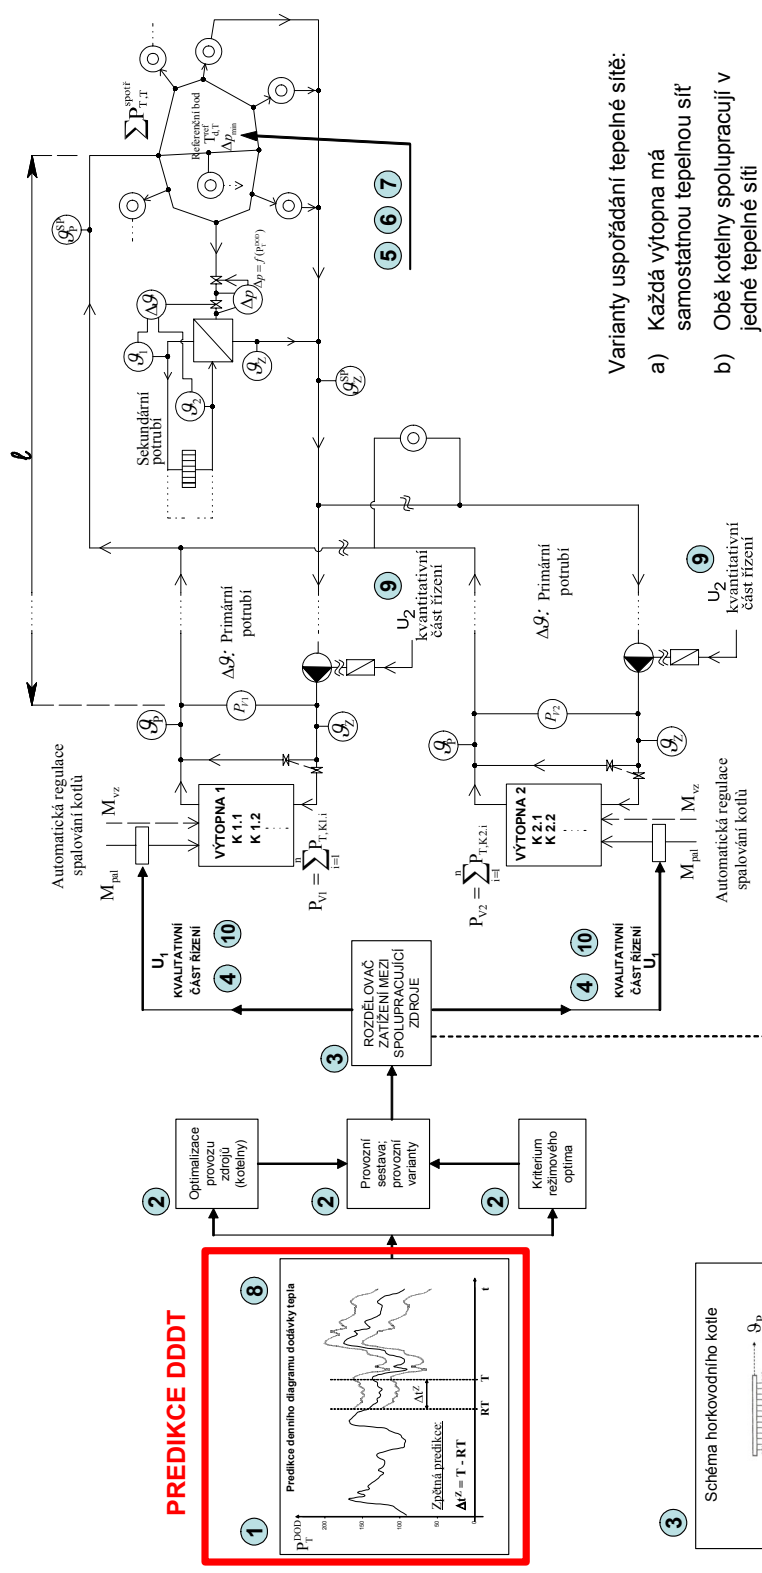
Jde o *opravu* hmotnostního toku horké vody čase T na oběhových čerpadlech $\Delta M_{v,T}$. Velikost je funkcí rozdílu ve spotřebě tepla u spotřebitelů horkovodní sítě v čase T a příkonu-tepelného výkonu v jednotlivých pracujících kotelnách v čase

RT odpovídající $u_{l,RT}$. Touto opravou bude dosaženo původní polohy charakteristiky potrubí horkovodní sítě (regulace na konstantní polohu charakteristiky potrubí).



10. *Korekce* KVALITATIVNÍ části řízení tj. výkonu kotlů Δu_l v čase T (oprava původního nastavení výkonů $u_{l,RT}$):

Legenda k Obr. 7.3:

l – délka přívodního větve tepelného napáječe, RT – reálný čas (čas, ve kterém působí akční veličina kvalitativního způsobu řízení na horkovodním kotli), T – čas, ve kterém se projeví působení akční veličiny kvalitativního způsobu řízení u lokálně soustředěných spotřebitelů, T_d – dopravní zpoždění, $T_{d,T}^{ref}$ - dopravní zpoždění v referenčním místě horkovodní sítě v čase T , Δt^Z – doba zpětné predikce (čas, o který je nutné dříve změnit akční veličinu kotlů, aby se změna tepelného výkonu horkovodního kotle kvalitativním způsobem řízení projevila v čase T , $P_T^{p.DOD}$ - předpověď denního diagramu dodávky (vyrobeného) tepelného výkonu - DDDT, $P_{T,Kj.i}$ - tepelný výkon horkovodního kotle č. i ve výrobně č. j , $\Delta \mathcal{G} = \mathcal{G}_p - \mathcal{G}_z$ - teplotní rozdíl v přívodním \mathcal{G}_p a zpětném \mathcal{G}_z potrubí horkovodní sítě, M_{pal} - hmotnostní tok paliva, M_{vz} - hmotnostní tok vzduchu, $\sum P_{T,T}^{spotř}$ - odebíraný tepelný výkon všemi spotřebiteli v čase T , $\Delta p^{čerp}$ – tlaková diference oběhového čerpadla v horkovodní síti, Δp^{ref} – tlaková diference v referenčním bodě zokruhované horkovodní sítě, P_{Vj} - tepelný výkon ve výrobně č. j , \mathcal{G}_p^{SP} - teplota horké vody v přívodním potrubí v síti spotřebitelů, \mathcal{G}_z^{SP} - teplota horké vody ve zpětném potrubí v síti spotřebitelů.



PREDIKCE DDDT



Obr. 7.3: Algoritmus kvalitativně-quantitativního způsobu řízení výkonu horkovodu s horkovodními kotli jako zdroji tepla

- Varianty uspořádání tepelné sítě:
- a) Každá výtopena má samostatnou tepelnou síť
 - b) Obě kotelny spolupracují v jedné tepelné síti

7.2 Optimální rozdělování zatížení

Výsledky předpovědi DDDT jsou určeny také pro účel řízení výroby tepla a tedy *optimálního rozdělování zatížení mezi spolupracující výrobní zdroje a v nich výrobních jednotek* (teplárny, výtopny, spalovny, dálkové napáječe). Prvořadým cílem těchto úloh je snížení nákladů spojených s provozem spolupracujících jednotek při dosažení stejného výrobního efektu. Předpověď pak slouží pro krátkodobou přípravu výroby v časovém horizontu 24 hodin, kdy určíme minimální spotřebu paliva a energie, což přispívá k ekonomii a ekologii provozu.

Pro optimální rozdělování zatížení se s výhodou používá metody funkce poměrných přírůstků.

7.2.1 Metoda funkce poměrných přírůstků

Jedná se o metodu vycházející z teorie vázaného extrému a vychází z požadavku minimální celkové spotřeby všech spolupracujících výrobních jednotek $P_{T,PAL}$ (v našem případě tepelných výrobních jednotek - kotlů) při zadaném celkovém výkonu $P_{T,VYR}$ (v našem případě vyrobený tepelný výkon celého tepelného zdroje).

$$P_{T,PAL}^{ZDROJE} = \sum_{i=1}^n P_{T,PAL}^i (P_{T,VYR}^i) \rightarrow \min \quad (7.1)$$

platí-li $\sum_{i=1}^n P_{T,VYR}^i = P_{T,VYR}^{ZDROJE}$

kde $P_{T,PAL}^{ZDROJE}$ [MW_t] spotřeba tepelného výkonu v palivu tepelného zdroje,

$P_{T,PAL}^i$ [MW_t] spotřeba tep. výkonu v palivu i-té vyr. jednotky (kotle),

$P_{T,VYR}^{ZDROJE}$ [MW_t] vyrobené teplo v tepelném zdroji,

$P_{T,VYR}^i$ [MW_t] vyrobené teplo v i-té výrobní jednotce (kotle),

n [-] počet výrobních jednotek (kotlů).

Řešení vychází z hledání extrému účelové funkce, v našem případě, jelikož provádíme minimalizaci výrobních nákladů, hledání minima této účelové funkce.

$$E = \sum_{i=1}^n b_K^i (P_{T,VYR}^i - P_{T,VYR,min}^i) \rightarrow \min \quad (7.2)$$


$$\frac{dP_{T,PAL}^i}{dP_{T,VYR}^i} = b_K^i \quad \text{pro } i = 1 \text{ až } n \quad (7.3)$$

kde E [MW_t] účelová funkce,

b_K^i [-] hodnota funkce poměrného přírůstku spotřeby i -té výrobní jednotky (kotle),


$P_{T,VYR,min}^i$ [MW_t] minimální vyrobené teplo v i -té výrobní jednotce (kotle).

Základem metody poměrných přírůstků je znalost spotřebních charakteristik jednotlivých výrobních jednotek (kotlů). Spotřební charakteristiky výrobních jednotek mohou mít konvexní, konkávní i lineární průběh, což je dáno typem výrobní jednotky. Ukázky typů spotřebních charakteristik a jim odpovídající průběhy funkcí poměrných přírůstků spotřeby jsou na následujících obrázcích .



Obr. 7.4: Typy spotřebních charakteristik

Konvexní tvar spotřební charakteristiky mají např. kotle i celý elektrárenský blok, lineární tvar např. elektrické generátory a transformátory, parní turbíny mají tvar spotřební charakteristiky konkávní.



Obr. 7.5: Odpovídající typy funkcí poměrných přírůstků spotřeby

Při zadaném úkolu optimalizace tepelného zdroje bude platit, že celková spotřeba tepelného výkonu v palivu tepelného zdroje se zvýší o $\Delta P_{T,PAL}^{ZDROJE}$.

$$\Delta P_{T,PAL}^{ZDROJE} = \sum_{i=1}^n b_K^i \Delta P_{T,VYR}^i \quad (7.4)$$

přičemž platí

$$\sum_{i=1}^n \Delta P_{T,VYR}^i = \Delta P_{T,VYR}^{ZDROJE} \quad (7.5)$$

Z toho vyplývá, že celkový přírůstek spotřeby tepelného výkonu v palivu $\Delta P_{T,PAL}^{ZDROJE}$ bude zřejmě nejmenší, jestliže se vyrobený tepelný výkon zvýší o $\Delta P_{T,VYR}^i$ u výrobní jednotky (kotle) s nejmenší hodnotou funkce poměrných přírůstků b_K^i ve výchozím stavu. Pro optimální provoz platí proto obecné pravidlo:

„Vyrobený tepelný výkon se přednostně zvyšuje u výrobní jednotky (kotle), která má ve výchozím stavu nejnižší hodnotu funkce poměrných přírůstků a obráceně se výkon snižuje u výrobní jednotky (kotle), která má ve výchozím stavu nejvyšší hodnotu funkce poměrných přírůstků“.

7.2.2 Návrh kritéria režimového optima

Abychom našli optimální provozní sestavy tepelných zdrojů, které jsou schopny co nejhospodárněji pokrýt odběratelskou spotřebu tepla v tepelné síti, je třeba brát v úvahu kritérium režimového optima. Kritérium režimového optima tedy spočívá v ekonomickém

zapojení jednotlivých zdrojů tepelné energie pro pokrytí odběratelské spotřeby tepla. Ideální nastavení zajišťuje minimální náklady na dodávku tepla a elektřiny odběratelům. Můžeme tedy konstatovat, že pro dané (předpověděné) celkové zatížení teplotní soustavy existuje pouze jediné optimální řešení rozdělení zatížení mezi spolupracujícími tepelnými zdroji a to takové, aby při další změně rozdělení zatížení již nebylo možno dosáhnout snížení vlastních nákladů.

Při návrhu kritéria režimového optima se tedy zaměřujeme na tepelné zdroje a jejich optimální vzájemnou spolupráci.

Výsledkem optimalizace tepelného zdroje je poměrný přírůstek tepelného výkonu v palivu na jednotku dodávaného tepelného výkonu, tedy

$$b_{DOD}^{ZDROJE} = \frac{dP_{T,PAL}^{ZDROJE}}{dP_{T,DOD}^{ZDROJE}} [-] \quad (7.6)$$

Poměrný přírůstek tepelného výkonu v palivu na jednotku dodávaného tepelného výkonu neobsahuje cenu paliva. Pro stanovení optimální provozní sestavy tepelných zdrojů v teplotní síti, je třeba uvažovat jednotlivé tepelné zdroje z hlediska:

- technologického typu tepelného zdroje,
- ekonomického, tedy podle použitého paliva,
- nákladů spojených s provozem tepelného zdroje.

Vlastní náklady dodávky tepla a elektřiny se skládají z nákladů na palivo, odpisy, běžnou údržbu a obsluhu zařízení na řídicí aparát. Dá se předpokládat, že kromě nákladů na palivo, ostatní složky nákladů nezávisí na rozdělení zatížení. Nabízí se tedy pro kritérium režimového optima minimum nákladů na palivo. Toto kritérium je velmi univerzální a umožňuje zevrubný rozbor hospodárnosti soustavy. Dále je možné jej použít jak pro lineární tak i nelineární model. Při návrhu kritéria režimového optima budeme vycházet z poměrného přírůstku spotřeby tepelného výkonu v palivu na dodanou jednotku tepla, tedy z b_{DOD}^{ZDROJE} pro jednotlivou provozní variantu. Kritérium režimového optima je ekonomickým kritériem, na jehož základě se rozhodujeme pro provozní sestavu zdrojů, která by co nejhospodárněji pokrývala odběratelskou spotřebu tepla v dané teplotní síti.

soustavě. Jelikož se tedy jedná o ekonomické kritérium, budou v něm hrát důležitou roli náklady nebo případné zisky spojené s provozem tepelného zdroje. Podstatou navrženého kritéria režimového optima bude cenový koeficient. Ten nebude tvořen jen cenou paliva, ale bude v něm zohledněna odebíraná elektrická energie na čerpací práce a dodávka elektrické energie do elektrizační sítě. Přírůstek pro dispečerské řízení b_{disp}^{ZDROJE} zahrnuje jak technické problémy řízení a regulace, tak i ekonomickou problematiku. Představuje tedy promítání ekonomických cílů při respektování technických podmínek. Pak navržený základní vztah kritéria režimového optima je

$$b_{disp}^{ZDROJE} = b_{DOD}^{ZDROJE} k_{PAL} \quad (7.7)$$

kde b_{disp}^{ZDROJE} [Kč/MW] přírůstek nákladů zdroje pro dispečerské řízení

k_{PAL} [Kč/MW] cenový koeficient

Jelikož se v tepelném zdroji nespotřebovává při výrobě tepelné energie jen palivo, ale i elektrická energie, nebo naopak se nevyrobí jen tepelná energie, ale i elektrická, měla by se tato skutečnost zohlednit v kritériu režimového optima, neboť náklady spojené se spotřebou elektrické energie, ale i výnosy získané prodejem elektrické energie mohou toto kritérium do značné míry ovlivnit. V současnosti je tato otázka velmi aktuální a je ovlivněna jednotlivými lokalitami. Při predikci dodávky tepla do teplárenské sítě, si provozovatel několik dní dopředu smluvně stanoví možné dodávky elektrické energie, které plynou z předpokládané výroby tepelné energie. Dodávky elektrické energie ze zdrojů (tepláren) v teplárenské síti tyto zdroje zvýhodňují oproti jiným, které elektrickou energii nedodávají. Dále je významné, v které části denního diagramu zatížení (elektrické spotřeby elektrizační soustavy) je zdroj s kombinovanou výrobou tepla a elektřiny (CHP) schopný dodat elektrickou energii do elektrizační soustavy. Případně můžeme akumulací tepla vyrovnávat případně upravovat průběh tepelného zatížení tak, aby se vytvořil ekonomicky výhodný provozní režim. Při výrobě energií v CHP rozlišujeme tzv. závislý a nezávislý elektrický výkon. Při čisté tepelné výrobě je rozhodující závislý elektrický výkon s nezávislým výkonem, které můžeme zohlednit v kritériu režimového optima.

Vzorec pro výpočet cenového koeficientu:

$$k_{PAL} = c_{PAL} b_{DOD}^{ZDROJE} - c_E^{DOD} b_{E,DOD}^{ZDROJE} + c_E^{SPOTŘ} b_{E,SPOTŘ}^{ZDROJE} \quad (7.8)$$

kde c_{PAL} [Kč/MW] cena paliva,
 c_{EDOD} [Kč/MW] cena dodané elektřiny do elektrizační sítě,
 $c_{ESpotř}$ [Kč/MW] cena spotřebované elektrické energie odebírané z elektrizační sítě.

$$b_{E,DOD}^{ZDROJE} = \frac{dP_{E,DOD}^{ZDROJE}}{dP_{T,DOD}^{ZDROJE}} \quad [-] \quad (7.9)$$

$$b_{E,SPOTŘ}^{ZDROJE} = \frac{dP_{E,SPOTŘ}^{ZDROJE}}{dP_{T,DOD}^{ZDROJE}} \quad [-] \quad (7.10)$$

Náklady spojené s čerpací prací v případě teplotního média horké vody se zahrnují do proměnné $b_{E,SPOTŘ}^{ZDROJE}$, stejně jako jiné náklady spojené s provozem teplotního zdroje v souvislosti s odebíranou elektrickou energií. Námí navržené kritérium režimového optima je univerzální pro všechny typy tepelných zdrojů.

Pro případ teplotní budou v úvahy brány všechny členy cenového koeficientu, tedy jak cena paliva, která bude tento cenový koeficient zvyšovat, tak i druhý člen, tedy zisk z výroby elektrické energie, který bude naopak tento cenový koeficient snižovat a v neposlední řadě i náklady spojené s odebíranou elektrickou energií, které budou opět působit na cenový koeficient směrem nahoru.

Pro případ výtopny nebude přítomný prostřední, tedy druhý člen, který daný zdroj zvyhodňoval, protože výtopna nevyrobí elektrickou energii.

Je zřejmé, že spalovna, která má téměř nulové náklady na palivo, bude mít cenový koeficient velmi nízký a celkový přírůstek nákladů b_{disp}^{ZDROJE} se bude jevit jako velmi výhodný. A to z důvodu, že spalovna má jako primární funkci likvidaci komunálního

odpadu a vyrobené teplo je vedlejší produkt. Teplo vzniklé spalováním musí být vždy odebráno, proto že spalovny jsou zařazeny SCZT do pásma se základním zatížením.

Na základě přírůstku nákladů jednotlivých zdrojů, tedy kritéria režimového optima, se stanovují optimální sestavy zdrojů na pokrytí odběratelské spotřeby tepla.

Pokud tedy shrneme předchozí úvahy, povede k nalezení optimální provozní sestavy tepelných zdrojů a jejich požadovaných dodávek tepelných výkonů minimalizace účelové funkce ve tvaru

$$E_1 = \sum_{i=1}^n b_{disp}^{ZDROJE(i)} P_{T,DOD}^{ZDROJE(i)} \Rightarrow \min \quad (7.11)$$

kde E_1 [Kč] účelová funkce pro nalezení provozní sestavy tepelných zdrojů z hlediska hospodárnosti

$b_{disp}^{ZDROJE(i)}$ [Kč/MW] přírůstek nákladů i-tého tepelného zdroje

$P_{T,DOD}^{ZDROJE(i)}$ [MW_t] množství dodávané tepelné energie z i-tého tepelného zdroje

Nalezení optimální provozní sestavy tepelných zdrojů, které pokryje odběratelskou spotřebu tepla, sice splňuje hospodárnost tepelné sítě, ale není v ní zohledněno dopravní zpoždění, které má nemalý vliv při řízení dodávky tepla. V parovodních typech sítí můžeme dopravní zpoždění zanedbat díky rychlosti páry v parovodu (80 m/s), zatímco v horkovodech je rychlost vody maximálně 2,5 m/s. Následně se snažíme najít takovou provozní sestavu tepelných zdrojů a jejich tepelných výkonů, aby byla splněna jak maximální hospodárnost, tak i zohledněna podmínka dopravní zpoždění.

Zohledňujeme-li v optimalizaci dopravní zpoždění, pak musíme upravit tvar účelové funkce, aby toto bylo v ní zohledněno. Účelová funkce řešící optimální návržení provozní soustavy tepelných zdrojů pro krytí odběratelské spotřeby tepla s využitím analýzy dopravního zpoždění bude mít tvar

$$E_2 = \left(\sum_{i=1}^n b_{disp}^{ZDROJE(i)} P_{T,DOD}^{ZDROJE(i)} \right) E_{Td} \Rightarrow \min \quad (7.12)$$

kde E_2 [Kč] účelová funkce pro nalezení provozní sestavy tepelných zdrojů z hlediska hospodárnosti a s využitím analýzy dopravního zpoždění

E_{Td} [h] koeficient průměrného dopravního zpoždění

Opětovně se snažíme o minimalizaci účelové funkce a tím nalezení "optimální" provozní sestavy tepelných zdrojů pro krytí požadované dodávky tepelné energie v tepelné síti a to jak z hlediska hospodárnosti tak i s přihlédnutím na analýzu dopravního zpoždění.

Celkový postup nalezení optimální provozní soustavy tepelných zdrojů pro danou dodávku tepla tedy **začíná predikcí, neboli předpovědí předpokládané dodávky tepelné energie do teplotenské sítě**. Na základě této předpokládané poptávky po tepelné energii se smluvně sjednají dodávky elektrické energie, které vyplývají ze závislého elektrického výkonu na tepelném. Tímto se stanoví dodávky tepelné energie z tepláren, které zajišťují výrobu nasmlouvané elektrické energie. Pro zajištění maximální hospodárnosti spolu s analýzou dopravního zpoždění se následně spustí algoritmus minimalizace účelové funkce pro nastavení optimálních provozních výkonů jednotlivých tepelných zdrojů.

8 ZÁVĚR

Podstatou disertační práce bylo rozpracovat metodologii Box-Jenkinse takovým způsobem, aby byla použitelná pro výpočet předpovědi průběhu časové řady denního diagramu dodávky tepla (DDDT) v soustavě centralizovaného zásobování teplem.

Jedním z cílů práce bylo navrhnout model časové řady DDDT. Touto problematikou se zabývá podrobně kapitola pátá. Tato kapitola mimo jiné odpovídá na otázku co je třeba všechno udělat s časovou řadou před vlastní predikcí. Jsou zde objasněny pojmy jako vyrovnaní časové řady, transformace časové řady, určení řádu diferencování a další. Tyto jednotlivé fáze výstavby modelu jsou pak prakticky ilustrovány na konkrétní časové řadě DDDT.

Hlavním přínosem práce je navržení metodologie pro zahrnutí nepravidelných kalendářních vlivů a zahrnutí vlivu meteorologických veličin do výpočtu předpovědi DDDT. Jde o řešení situace, kdy státem uznávaný svátek resp. den pracovního klidu případně na pracovní den a situace náhlých výkyvů počasí. Při zahrnutí meteorologických veličin jsme se omezili pouze na vliv venkovní teploty, která má na průběh DDDT největší vliv.

Přímým výstupem je pak komplexní výpočetní program v prostředí MATLAB, který může sloužit především pro provozovatele popřípadě projektanty tepelných sítí.

Řešení předpovědi DDDT má svůj praktický význam nejenom při projekci teplotních soustav, ale především při samotném provozu. Znalost budoucích hodnot spotřeby tepla v horizontu 24 hodin může být pro dispečery v teplárnách velmi užitečná. Taková předpověď vede k eliminaci dopravního zpoždění, k úspoře paliv a energie, což přispívá k ekonomii a ekologii provozu.

Je nutné zdůraznit, že konkrétní výpočty proběhly na reálných datech, které byly získány díky úzké spolupráci výzkumného pracoviště s provozem v energetických podnicích. V našem případě se jednalo o úzkou spolupráci s MST a.s. –Teplárnou Olomouc, respektive s Teplárnou Otrokovice, a.s.

9 PUBLIKAČNÍ AKTIVITY

- CHRAMCOV, B., BALÁTĚ, J. (1998). Výpočet předpovědi časové řady tepelného výkonu horkovodu v rytmu změn denního diagramu dodávky tepla pro řízení v reálném čase. In *Proceedings of the 3rd International conference: New Trends of Automation in Energetic Processes '98*, page 153-158, Květen 1998, VUT FT ve Zlíně, Zlín.
- CHRAMCOV, B., BALÁTĚ, J. (1998). Výpočet předpovědi časové řady tepelného výkonu horkovodu v rytmu změn denního diagramu dodávky tepla pro řízení v reálném čase. *Sborník referátů - XXI. Seminář ASŘ '98*, str.6, ISBN 80-7078-559-4, Květen 1998, VŠB TU Fakulta strojní v Ostravě, Ostrava.
- CHRAMCOV, B., BALÁTĚ, J. (1999). Testování matematického statistického modelu předpovědi denního diagramu dodávky tepla. *Sborník referátů - XXIII. Seminář ASŘ '99*, str.25, ISBN 80-7078-666-3, Duben 1999, VŠB TU Fakulta strojní v Ostravě, Ostrava.
- CHRAMCOV, B., BALÁTĚ, J. (1999). Selection of Mathematics Model for Daily Diagram Prediction According to Box-Jenkins Method. *Appendix to Proceeding: 7th Zittau Fuzzy Coloquium '99*, page 257, September 1999, IPM Hochschule Zittau/Görlitz, Zittau.
- CHRAMCOV, B., BALÁTĚ, J. (1999). Selection of Available Model for Calculation of Prediction of Heat Supply Daily Diagram Course on the Base of Real Data. In *Proceedings of the 10th International DAAAM symposium*, 2 pages, ISBN 3-901509-10-0, October 1999, Vienna University of technology, Vienna, Austria.
- CHRAMCOV, B., BALÁTĚ, J. (1999). Calculation of Prediction of Heat Supply Daily Diagram. In *Proceedings of the International conference: District Heating Control '99*, page 85-91, ISBN 80-214-1461-8, October 1999, VUT FT ve Zlíně, Zlín.
- CHRAMCOV, B., BALÁTĚ, J., PRINC, M. (2000). Prediction of Heat Supply Daily Diagram; Utilization for District Heating Control. In *Proceedings the 4 th International Scientific-Technical Conference „Process Control 2000“*, p. 91, ISBN 80-7194-271-5,

Kouty nad Desnou, June 2000, Faculty of Chemical Technologie of the University of Pardubice.

PRINC, M., BALÁTĚ, J., CHRAMCOV, B. (2000). Solving of hydraulic and heat properties of heat networks. *In Proceedings the 4 th International Scientific-Technical Conference „Process Control 2000“*, p. 92, ISBN 80-7194-271-5, Kouty nad Desnou, June 2000, Faculty of Chemical Technologie of the University of Pardubice.

CHRAMCOV, B., BALÁTĚ, J., PRINC, M. (2000). Využití předpovědi denního diagramu dodávky tepla pro řízení v soustavách centralizovaného zásobování teplem. *Zborník 4. medzinárodnej konferencie „Riadenie v energetike“*, str. 313-318, ISBN 80-227-1354-6, Červen 2000, STU – FEI v Bratislavě, Vydavatelství Slovenské technické univerzity v Bratislavě.

PRINC, M., BALÁTĚ, J., CHRAMCOV, B. (2000). Řešení hydraulických a tepelných vlastností tepelných sítí. *Zborník 4. medzinárodnej konferencie „Riadenie v energetike“*, str. 302-307, ISBN 80-227-1354-6, Červen 2000, STU – FEI v Bratislavě, Vydavatelství Slovenské technické univerzity v Bratislavě.

BALÁTĚ, J., CHRAMCOV, B., PRINC, M. (2000). Computer Aided Automatic Control – CAAC – Artificial Intelligence Block. *Proceeding of 8th Zittau Fuzzy Colloquium*, p. 173-181, ISBN 3-00-006723-X, September 2000, University of Applied Sciences, Zittau.

CHRAMCOV, B., BALÁTĚ, J., PRINC, M. (2000). Využití předpovědi denního diagramu dodávky tepla pro řízení v soustavách centralizovaného zásobování teplem. *Proceedings of the 2nd DAAAM Workshop*, str. 13-14, ISBN 3-901509-18-6, Editor B. Katalinic and E. Wessely, November 2000, TU Košice, Slovenská republika.

PRINC, M., BALÁTĚ, J., CHRAMCOV, B. (2000). Řešení hydraulických a tepelných vlastností tepelných sítí. *Proceedings of the 2nd DAAAM Workshop*, str. 67-68, ISBN 3-901509-18-6, Editor B. Katalinic and E. Wessely, November 2000, TU Košice, Slovenská republika.

- BALÁTĚ, J., HRUŠKA, F., CHRAMCOV, B. PRINC, M., PHAN T. D. (2001).
Informace o řešení řízení rozlehlých teplotních soustav. *Sborník konference AUTOS 2001*, str. 132-140, ISSN 1212-5709, Duben 2001, Praha.
- CHRAMCOV, B., BALÁTĚ, J., PRINC, M. (2001). Prediction of Heat Supply Daily Diagram. *In proceeding of International Carpathian Control Conference – ICC 2001*, p. 255-260, ISBN 83-91340-07-4, AGH Krakov , May 2001, Krynica, Poland.
- PRINC, M., BALÁTĚ, J., CHRAMCOV, B. (2001). Solving of Hydraulic and Heat Relations of Heat Networks. *In proceeding of International Carpathian Control Conference – ICC 2001*, p. 597-602 , ISBN 83-91340-07-4, AGH Krakov , May 2001, Krynica, Poland.
- BALÁTĚ, J., CHRAMCOV, B., PRINC, M. (2001). Behaviour Analysis and Control of Heat Networks Economical Operation. *Summaries Volume of the 13th International Conference on Process Control '01*, p.200, ISBN 80-227-1542-5, Slovak University of Technology in Bratislava, June 11-14, Štrbské Pleso, Slovak Republic
- BALÁTĚ, J., CHRAMCOV, B., PRINC, M. (2001). Building Up Of District Heating Control. *In Proceeding of International Conference „ENERGY FORUM 2001“*, p.147-, 150. Technical University in Sofia, June 10-12, Varna, Bulgaria.
- CHRAMCOV, B., DOSTÁL, P., BALÁTĚ, J. (2002). Inclusion of Weather Influences in Calculation of Heat Supply Daily Diagram Forecast. *Proceedings of Annotations of the 5th International Conference Control of Power & Heating Systems 2002*, p.82-83, ISBN 80-7318-074-X, Tomas Bata University in Zlín, May 21-22, Zlín, Czech Republic.
- PRINC, M., BALÁTĚ, J., CHRAMCOV, B. (2002). Analysis of Hydraulic and Heat Relations in Heat Networks; Calculation in Real Locality. *Proceedings of the 3rd International Carpathian Control Conference*, p. 775-780, ISBN 80-248-0089-6, VŠB-Technical University of Ostrava, May 27-30, Malenovice, Czech Republic.
- CHRAMCOV, B., BALÁTĚ, J., PRINC, M. (2002). Inclusion of Weather Influences in Calculation of Heat Supply Daily Diagram Forecast. *Proceedings of the 3rd*

- International Carpathian Control Conference*, p. 769-774, ISBN 80-248-0089-6, VŠB-Technical University of Ostrava, May 27-30, Malenovice, Czech Republic.
- BALÁTĚ, J., PRINC, M., CHRAMCOV, B. (2002). Analýza a syntéza řízení horkovodní sítě; návrh pro konkrétní lokalitu. *Zborník abstraktov medzinárodnej konferencie Kybernetika a informatika*, p. 109-110, ISBN 80-227-1749-5, Vydavateľstvo STU v Bratislavě, 4.-6. září 2002, Trebišov, Slovenská republika.
- DOSTÁL, P., BALÁTĚ, J., CHRAMCOV, B. (2002). Prediction of the Heat Supply Daily Diagram via Artificial Neural Network. *Proceedings of the 10th Zittau Fuzzy Colloquium*, p.178-183, ISBN 3-9808089-2-0, University of Applied Sciences Zittau/Görlitz, September 4-6, Zittau, Germany.
- BALÁTĚ, J., CHRAMCOV, B., PRINC, M., HAMPEL, R. (2002). Conception of Design of District Heating Control. *Beitragsmanuskripte der XXXIV. Kraftwerkstechnisches Kolloquium*, p. 185-194, Technische Universität Dresden, September 24-25, Dresden.
- CHRAMCOV, B., BALÁTĚ, J., PRINC, M. (2002). Inclusion of Weather Influences in Calculation of Heat Supply Daily Diagram Forecast. *Proceedings of the 13th International DAAAM Symposium „Intelligent Manufacturing & Automation: Learnig from Nature“*, p. 91-92, ISBN 3-901509-29-1, DAAAM International Vienna, October 23-26, Vienna, Austria.
- BALÁTĚ, J., CHRAMCOV, B. & PRINC, M. (2003): Strategy of Control of Extensive District Heating Systems. *In: Proceedings of the IFAC Symposium on Power Plants & Power Systems Control 2003*, vol. II, pp. 762-767, ISBN není uvedeno, KIEE, 15.-19.9.2003, Seoul, Korea.
- BALÁTĚ, J., CHRAMCOV, B. & PRINC, M. (2003): Strategy and Philosophy of District Heating Systems Control. *In: Abstracts Volume of the 2nd IFAC Conference Control Systems Design '03*, p. 41, ISBN není uvedeno, 7.-10.9.2003, Bratislava, Slovak Republic.
- DOSTÁL, P., CHRAMCOV, B. & BALÁTĚ, J. (2003): Soft Computing and Control of District Heating System. *In: Proceedings of the 3rd Eusflat International Conference in*

- Fuzzy Logic and Technology*, p. 480-484, ISBN 3-9808089-4-7, European Society for Fuzzy Logic and Technology, 10.-12.9.2003, Zittau, Germany.
- CHRAMCOV, B. & PETERKA, J. (2003): Utilisation of Fuzzy Models for the Prediction of the Heat Supply Daily Diagram. *In: Proceedings of the 7th International Research/Expert Conference "Trends in the Development of Machinery and Associated Technology" TMT 2003*, p. 893-896, ISBN 9958-617-18-8, Universitat Politecnica de Catalunya, 15.-17.9.2003, Lloret de Mar, Barcelona, Spain.
- CHRAMCOV, B. & BALÁTĚ, J. (2003): Prediction of the Heat Supply Daily Diagram via Artificial Neural Network. *In: Proceedings of the 4th International Carpathian Control Conference ICCC 2003*, p. 703-706, ISBN 80-7099-509-2, TU Košice, 26.-29.5.2003, Tatranská Lomnica, Slovak Republic.
- BALÁTĚ, J., CHRAMCOV, B. & PRINC, M. (2003): Conception of Design of District Heating Control. *In: Summaries Volume of the 14th International Conference Process Control 2003*, p. 145, ISBN 80-227-1902-1, Slovak University of Technology in Bratislava, 8.-11.6.2003, Štrbské Pleso, Slovak Republic.
- CHRAMCOV, B. (2003): Využití předpovědi denního diagramu dodávky tepla pro řízení teplotních soustav. *Sborník 7. ročníku konference "Inteligentní systémy pro praxi"*, Str.17, ISBN 80-239-0201-6, AD&M, Ostrava Poruba, 18.-19.2.2003, Seč u Chrudimi.
- BALÁTĚ, J. & CHRAMCOV, B. (2004): The Way of District Heating Output Control by Means of Hydrothermal Power Systems – Three Modifications. *In: Proceedings of the 5th International Carpathian Control Conference ICCC 2004*, p. 15-22, ISBN 83-89772-00-0, AGH UST Krakow, 25.-28.5.2004, Zakopane, Poland.
- CHRAMCOV, B. & PETERKA, J. (2004): Utilization of Fuzzy Models for the Prediction of the Heat Supply Daily Diagram. *In: Proceedings of the 5th International Carpathian Control Conference ICCC 2004*, p. 807-814, ISBN 83-89772-00-0. AGH UST Krakow, 25.-28.5.2004, Zakopane, Poland.
- CHRAMCOV, B. & PETERKA, J. (2004). Use of the Fuzzy Logic Toolbox in Matlab for the Prediction of the Heat Supply Daily Diagram. *Proceedings of the 11th East West*

Fuzzy Colloquium, p.56-62, ISBN 3-9808089-5-5, University of Applied Sciences Zittau/Görlitz, September 8-10, Zittau, Germany.

CHRAMCOV, B. & PETERKA, J. (2004): Inclusion of Outdoor Temperature Influence for Calculation of the Heat Supply Daily Diagram. *In: Proceedings of the 8th International Research/Expert Conference "Trends in the Development of Machinery and Associated Technology" TMT 2004*, p. 795-798, ISBN 9958-617-21-8, University of Zenica, 15.-19.9.2004, Neum, Bosnia and Herzegovina.

CHRAMCOV, B. & BALÁTĚ, J. (2004). Zahnutí vlivu venkovní teploty do výpočtu předpovědi denního diagramu dodávky tepla. *Zborník abstraktov 6. medzinárodnej konferencie „Riadenie v energetike 04“*, str. 225, ISBN 80-227-2059-3, 16.-18.6 2004, STU – FEI v Bratislavě, Vydavatelství STU v Bratislavě.

BALÁTĚ, J. & CHRAMCOV, B. (2004). Kvalitativně-quantitativní způsob řízení tepelného výkonu horkovodu při dodávce tepla do SCZT z roštových kotlů. *Zborník abstraktov 6. medzinárodnej konferencie „Riadenie v energetike 04“*, str. 158, ISBN 80-227-2059-3, 16.-18.6 2004, STU – FEI v Bratislavě, Vydavatelství STU v Bratislavě.

CHRAMCOV, B., BALÁTĚ, J. (2004). Prediction of Heat Supply Daily Diagram – Inclusion of irregular calendar influences. *In Proceedings the 6 th International Scientific-Technical Conference „Process Control 2004“*, p. 50, ISBN 80-7194-662-1, Kouty nad Desnou, June 2004, University of Pardubice.

CHRAMCOV, B., BALÁTĚ, J., JENÍK, P., KOPA, J. & PRINC, M. (2004): Využití předpovědi denního diagramu dodávky tepla při řízení teplotních soustav. *Sborník odborné konference s mezinárodní účastí „Teplotní dny 2004“*, 11 stran, ISBN není uvedeno, Teplotní sdružení ČR, 27.-29.4.2004, Hradec Králové.

PRINC, M., BALÁTĚ, J., JENÍK, P., KOPA, J. & CHRAMCOV, B. (2004): Využití analýzy hydraulických a teplotních poměrů v horkovodních sítích pro řízení dodávky tepla. *Sborník odborné konference s mezinárodní účastí „Teplotní dny 2004“*, 8 stran, ISBN není uvedeno, Teplotní sdružení ČR, 27.-29.4.2004, Hradec Králové.

BALÁTĚ, J., JENÍK, P & CHRAMCOV (2005): The Way of District Heating Output Control by Means of Hydrothermal Power Systems. *In: Proceedings of the 16th IFAC World Congress 2005*, 4.-8.7.2005, Praha.

CHRAMCOV, B. (2005): Prediction of Heat Supply Daily Diagram - Inclusion of Irregular Calendar Influences. *In: Proceedings of the 9th International Research/Expert Conference "Trends in the Development of Machinery and Associated Technology" TMT 2005*, p. 579-582, ISBN 9958-617-28-5, University of Zenica, 26.-30.9.2005, Antalya, Turkey.

CHRAMCOV, B. (2005). Prediction of Heat Supply Daily Diagram - Inclusion of Outdoor Temperature Influence. *Proceedings of the 16th International DAAAM Symposium „Intelligent Manufacturing & Automation: Focus on Young Researches and Scientists“*, p. 69-70, ISBN 3-901509-46-1, DAAAM International Vienna, October 19-22, Opatija, Croatia.

Část knihy:

BALÁTĚ, J., CHRAMCOV, B. (2000). Selection of Mathematics Model for Daily Diagram Prediction According to Box-Jenkins Method. *In Advanced in Soft Computing – Fuzzy Control – Theory and Practice*, Ed.: R. Hampel, M. Wagenknecht, N. Chaker, p 252-258, ISBN 3-7908-1327-3, Physica-Verlag, Heildeberg.

BALÁTĚ, J., CHRAMCOV, B. & PRINC, M. (2003). Conception of Design of District Heating Control. *In DAAAM International Scientific Book 2003*, Ed. Katalinic, B., p. 19-34, ISSN 1726-9687, ISBN 3-901509-30-5, DAAAM International Vienna, Vienna, Austria.

Časopisy:

BALÁTĚ, J., CHRAMCOV, B., PRINC, M. (2002). Experience of Proposal Creating in the Subject of District Heating Control in the Frame of 5th Framework Programme of European Union. *ACTA MECHANICA SLOVACA*, roč. 6. 2002, č. 2, s. 203-212. ISSN 1335-2393.

CHRAMCOV, B., DOSTÁL, P., BALÁTĚ, J. (2002). Zahrnutí vlivu meteorologických veličin do výpočtu předpovědi denního diagramu dodávky tepla. *Automatizace*, č. 11/2002, str. 704-706, ISSN 0005-125X.

Výzkumné zprávy:

CHRAMCOV, B. (2002). Závěrečná zpráva grantového projektu Fondu rozvoje VŠ MŠMT č. G1/0056, FT-UTB ve Zlíně.

Závěrečná zpráva GA ČR č. 101/01/0345, Příloha č. 3, číslo výzkumné zprávy VZ UTB-FT-IIT/2003/3, název CHRAMCOV, B.: Předpověď denního diagramu dodávky tepla, leden 2004.

Mimo výše popsaných konferenčních příspěvků jsem uveden jako **vedoucí těchto diplomových a bakalářských závěrečných prací:**

- 1 PETERKA, J. *Využití fuzzy logiky pro předpověď denního diagramu dodávky tepla*, diplomová práce, UTB ve Zlíně, FT, IIT, 2003.
- 2 MIKULENKOVÁ, M. *Programové prostředí MATHEMATICA – Elektronická příručka k cvičení z předmětu Základy informatiky*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2004.
- 3 HAVLÍČEK, P. *Stanice pro měření meteorologických veličin*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2004.
- 4 KLAČÁNEK, R. *Návrh struktury snímače pro systém řízení vulkanizačního stroje z pohledu ekonomické nenáročnosti*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.
- 5 HRABEC, T. *Řešení systému lineárních algebraických rovnic metodou Monte Carlo*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.
- 6 BÖNISCH, M. *Využití statistické metody Monte Carlo pro výpočet určitých integrálů*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.
- 7 HRANČÍK, L. *Elektronická podpora pro předmět Základy informatiky*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.
- 8 DANÍČEK, L. *Využití geometrické pravděpodobnosti při experimentálním ověření Ludolfova čísla*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.
- 9 JANKŮ, Z. *Příprava elektronické učební pomůcky pro předmět Základy informatiky*, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.

10 LITERATURA

- ABRAHAM, A., NATH, B. (2001). A Neuro-fuzzy approach for modelling electricity demand in Victoria, *Applied Soft Computing*, Volume 1, Issue 2, August 2001, pages 127-138.
- AL-HAMADI, H.M., SOLIMAN, S.A. (2004). Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model. *Electric Power Systems Research*, Volume 68, Issue 1, January 2004, pages 47-59, ISSN 0378-7796.
- AMJADY, N. (2001). Short-term hourly load forecasting using time-series modeling with peak load estimation capability. *IEEE Transactions on Power Systems*, Volume 16, Issue 4, November 2001, Pages 798-805.
- ANDĚL, J. (1976). *Statistická analýza časových řad*. SNTL, Praha.
- ARVASTSON, L. (2001). Stochastic modelling and operational optimization in district-heating systems. *PhD thesis*. Mathematical Statistics, Lund University, Lund, Sweden, 2001, ISBN 91-628-4855-0.
- BOLZERN, P., FRONZA, G. (1986). Role of weather inputs in short-term forecasting of electric load, *International Journal of Electrical Power & Energy Systems*, Volume 8, Issue 1, January 1986, Pages 42-46, ISSN 0142-0615.
- BOOKER, L.B. GOLDBERG D.E., HOLLAND, J.H. (1989). Classifier systems and genetic algorithms. *Artificial Intelligence*, Volume 40, Issues 1-3, September 1989, Pages 235-282.
- BOX, G.E.P., COX, D.R. (1964). An analysis of transformation. *Journal of Royal Statistical Society*, Volume B26, pages 211-252.
- BOX, G.E.P., JENKINS, G.M. (1976). *Time Series Analysis, Forecasting and Control*. Holden Day, ISBN 0-13-905100-7, San Francisco.
- BUNN, D.W., FARMER E.D. (1985). *Comparative models for Electric Load Forecasting*, New York, John Willey, 1985.

- CIPRA, T. (1986). *Analýza časových řad s aplikacemi v ekonomii*. SNTL, Praha.
- CROMWELL, J.B., LABYS, W.S., TERRAZA, M. (1994). *Univariate Tests for Time Series Models*. SAGE Publication, ISBN 0-8039-4991-X, Thousand Oaks, California.
- DJUKANOVIC, M., RUZIC, S., BABIC, B., SOBAJIC, D.J., PAO, Y.H. (1995). A neural-net based short term load forecasting using moving window procedure, *International Journal of Electrical Power & Energy Systems*, Volume 17, Issue 6, December 1995, pages 391-397, ISSN 0142-0615.
- DOSTÁL, P. (1986). Strojové zpracování předpovědi průběhu denního diagramu zatížení soustavy centralizovaného zásobování teplem. *Disertační práce*. Fakulta strojní VUT, Brno.
- DOTZAUER, E. (2002). Simple model for prediction of loads in district-heating systems. *Applied Energy*, Volume 73, November-December 2002, pages 277-284, ISSN 0306-2619.
- EKWUE, A.O., SHORT, M.J. (1990). On the use of statistical software package for load predictions for developing power systems. *International Journal of Electrical Power & energy Systems*, Volume 12, Issue 1, January 1990, pages 37-42, ISSN 0142-0615.
- ELKATEB, M.M., SOLAIMAN, K., AL-TURKI, Y. (1998). A comparative study of medium-weather-dependent load forecasting using enhanced artificial/fuzzy neural network and statistical techniques. *Neurocomputing*, Volume 23, Issues 1-3, December 1998, pages 3-13, ISSN 0925-2312
- EL-KEIB, A.A., MA, X., MA H. (1995). Advancement of statistical based modeling techniques for short-term load forecasting. *Electric Power Systems Research*, Volume 35, Issue 1, October 1995, Pages 51-58, ISSN 0378-7796.
- ENGLE, R., MUSTAFA, C., RICE, J. (1992). Modeling peak electricity demand. *Journal of Forecasting*, Volume 11, 1992, pages 241-251.
- FRANCES, P.H. (1998). *Time Series Models for Business and Economic Forecasting*. Cambridge University Press, Cambridge, UK.

- GOLDBERG, D.E. (1994). Genetic and evolutionary algorithms come of age. *Communications of the ACM*, Volume 37, Issue 3, March 1994, Pages 113-119.
- GOLDBERG, D.E., CHIE H.K. (1987). Genetic algorithms in pipeline optimization. *Journal of Computing in Civil Engineering*, Volume 1, Issue 2, April 1987, Pages 128-141.
- HAGAN, M.T., BEHR, S.M. (1987). The time series approach to short-term load forecasting. *IEEE Transaction on Power Systems*, Volume 2, Issue 3, August 1987, pages 785–791, ISSN 0885-8950.
- HARVEY, A., KOOPMAN, S. (1993). Forecasting hourly electricity demand using time-varying splines. *Journal of the American Statistical Association*, Volume 88, Issue 424, December 1993, pages 1228–1253, ISSN 0162-1459.
- HEINE, S., NEUMANN, I. (1994). Optimal load forecast models using an evolutionary algorithm. *Proceedings of the 2nd European Congress on Intelligent Techniques and Soft Computing*. pages 1690–1694, Aachen, Germany, 1994.
- HINTON, G.E. (1992). How neural networks learn from experience. *Scientific American*, Volume 267, Issue 3, September 1992, Pages 144-151.
- HINTON, G.E. (2000). Computation by neural network. *Nature Neuroscience*, Volume 3, Supplement, November 2000, Page 1170.
- HIPPERT, H.S., PEDREIRA, C.E., SOUZA, R.C. (2001). Neural networks for short-term forecasting: a review and evaluation. *IEEE Transactions on Power Systems*, Volume 16, Issue 1, February 2001, pages 44–55, ISSN 0885-8950.
- HO, K., HSU, Y., CHEN, C., LEE, T., LIANG, C., LAI, T., CHEN, K. (1990). Short term load forecasting of Taiwan power system using a knowledge-based expert system. *IEEE Transactions on Power Systems*, Volume 5, Issue 4, November 1990, pages 1214–1221, ISSN 0885-8950.
- HO, K.L., HSU, Y.Y., YANG, C.C. (1992). Short term load forecasting using a multilayer neural network with an adaptive learning algorithm. *IEEE Transactions on Power Systems*, Volume 7, Issue 1, February 1992, pages 259–266, ISSN 0885-8950.

- HUANG, S.R. (1997). Short-term load forecasting using threshold autoregressive models. *IEE Proceedings-Generation Transmission and Distribution*, Volume 144, Issue 5, September 1997, pages 477–481, ISSN 1350-2360.
- CHARYTONIUK, W., CHEN, M.S., VAN OLINDA, P. (1998). Non-parametric regression based short-term load forecasting. *IEEE Transaction on Power Systems*, Volume 13, Issue 3, August 1998, pages 725–730, ISSN 0885-8950.
- CHAVEZ, S.G., BERNAT, J.X., COALLA, H.L. (1999). Forecasting of energy production and consumption in Asturias (northern Spain). *Energy*, Volume 24, Issue 3, March 1999, pages 183-198, ISSN 0360-5442.
- CHEN, G.J., LI, K.K., CHUNG, T.S., SUN, H.B., TANG, G.Q. (2001). Application of an innovative combined forecasting method in power system load forecasting. *Electric Power System Research*, Volume 59, Issue 2, September 2001, pages 131–137, ISSN 0378-7796.
- CHEN, S.T., YU, D.C., MOGHADDAMJO, A.R., LU, C.N., VEMURI, S. (1992). Weather sensitive short-term load forecasting using non-fully connected artificial neural network. *IEEE Transactions on Power Systems*, Volume 7, Issue 3, August 1992, pages 1098-1105, ISSN 0885-8950.
- INFIELD, D.G., HILL, D.C. (1998). Optimal smoothing for trend removal short term electricity demand forecasting. *IEEE Transaction on Power Systems*, Volume 13, Issue 3, August 1998, pages 1115–1120, ISSN 0885-8950.
- JABBOUR, K., RIVEROS, J., LANDSBERGEN. W., MEYER. W. (1988). ALFA: automated load forecasting assistant. *IEEE Transaction on Power Systems*, Volume 3, Issue 3, August 1988, pages 908–14, ISSN 0885-8950.
- KALAITZAKIS, K., STAVRAKAKIS, G.S., ANAGNOSTAKIS, E.M. (2002). Short-term load forecasting based on artificial neural networks parallel implementation, *Electric Power Systems Research*, Volume 63, Issue 3, October 2002, pages 185-196, ISSN 0378-7796.
- KIARTZIS, S., KEHAGIAS, A., BAKIRTZIS, A., PETRIDIS, V. (1997). Short-term load forecasting using a Bayesian combination method. *International Journal of Electrical*

- Power & Energy Systems*, Volume 19, Issue 3, March 1997, pages 171–177, ISSN 0142-0615.
- KIM, K., PARK, J., HWANG, K., KIM, S. (1995). Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems. *IEEE Transaction on Power Systems*, Volume 10, Issue 3, August 1995, pages 1534-1539.
- KODOGIANNIS, V.S., ANAGNOSTAKIS, E.M. (1999). A study of advanced learning algorithms for short-term load forecasting. *Engineering Applications of Artificial Intelligence*, Volume 12, Issue 2, April 1999, pages 159–73, ISSN 0952-1976.
- LEE, K.Y., CHA, Y.T., PARK, J.H., KURZYN, M.S., PARK, D.C., MOHAMMED, O.A. (1992). Short-term Load Forecasting Using an Artificial Neural Network. *IEEE Transactions on Power Systems*, Volume 7, Issue 1, February 1992, pages 124-132, ISSN 0885-8950.
- LEHTORANTA, O., SEPPÄLÄ, J., KOIVISTO, H., KOIVO, H. (2000). Adaptive district heat load forecasting using neural networks. *Proceedings of Third international Symposium on Soft Computing for Industry*, Maui, USA, June, 2000.
- LIANG, R.H., CHENG, C.C. (2002). Short-term load forecasting by a neuro-fuzzy based approach, *International Journal of Electrical Power & Energy Systems*, Volume 24, Issue 2, February 2002, pages 103-111, ISSN 0142-0615.
- LU C.N., WU, H.T., VEMURI, S. (1993). Neural network based short term load forecasting. *IEEE Transactions on Power Systems*, Volume 8, Issue 1, February 1993, pages 337–342, ISSN 0885-8950.
- MAIFELD, T., SHEBLE, G. (1994). Short-term load forecasting by a neural network and a refined genetic algorithm. *Electric Power System Research*, Volume 31, Issue 3, December 1994, pages 147–52, ISSN 0378-7796.
- MANDAL, J.K., SINHA, A.K., PARTHASARATHY, G. (1995). Application of recurrent neural network for short term load forecasting in electric power system. *Proceedings of IEEE International Conference on Neural Networks – ICNN '95*, vol. 5., pages 2694–2698, November 27-December 1 1995, Perth, Western Australia.

- MASTOROCOSTAS, P.A., THEOCHARIS, J.B., KIARTZIS, S.J., BAKIRTZIS, A.G. (2000). A hybrid fuzzy modeling method for short-term load forecasting. *Mathematics and Computers in Simulation*, Volume 15, January 2000, pages 221–32, ISSN 0378-4754.
- MBAMALU, G.A.N., EL-HAWARY, M.E. (1993). Load forecasting suboptimal seasonal autoregressive models and iteratively reweighted least-squares estimation. *IEEE Transactions on Power Systems*, Volume 8, Issue 1, February 1993, Pages 343-348.
- MINAI, A.A., WILLIAMS, R.D. (1990). Back-propagation heuristics: A study of the extended Delta-Bar-Delta algorithm. *Proceedings of International Joint Conference on Neural Networks - IJCNN 90*, Pages 595-600, San Diego, Jun, 1990, Published by IEEE, PISCATAWAY, NJ, USA.
- MORI, H., KOBAYASHI, H. (1996). Optimal fuzzy inference for short-term load forecasting. *IEEE Transaction on Power Systems*, Volume 11, Issue 1, February 1996, pages 390–396, ISSN 0885-8950.
- NAKAMURA, M. (1985). Short term load forecasting using daily updated load models. *Automatica*, Volume 21, Issue 6, November 1985, Pages 729-736, ISSN 0005-1098.
- NAVARA, M., OLŠÁK, P. (2002). *Základy fuzzy množin*. Vydavatelství ČVUT , ISBN 80-01-02585-3, Praha.
- NOVÁK, M. (1998). *Umělé neuronové sítě : teorie a aplikace*. C. H. Beck, ISBN 80-7179-132-6, Praha.
- NOVÁK, V. (1990). *Fuzzy množiny a jejich aplikace*. Státní nakladatelství technické literatury, Praha.
- NOWICKA-ZAGRAJEK, J., WERON, R. (2002). Modelling electricity loads in California: ARMA models with hyperbolic noise. *Signal Processing*, Volume 82, Issue 12, December 2002, Pages 1903-1915.
- PAPADAKIS, S.E., THEOCHARIS, J.B., KIARTZIS, S.J., BAKIRTZIS, A.G. (1998). A novel approach to short-term load forecasting using fuzzy neural networks. *IEEE*

- Transactions on Power Systems*, Volume 13, Issue 2, May 1998, pages 480–92, ISSN 0885-8950.
- PAPALEXOPOULOS, A.D., HAO, S.Y., PENG, T.M. (1994). An implementation of a neural network based load forecasting model for the EMS. *IEEE Transactions on Power Systems*, Volume 9, Issue 4, November 1994, pages 1956–1962, ISSN 0885-8950.
- PARK, D.C., ELSHARKAWI, M.A., MARKS, R.J., ATLAS, L.E., DAMBORG, M.J. (1991). Electric load forecasting using an artificial neural network. *IEEE Transactions on Power Systems*, Volume 6, Issue 2, May 1991, pages 442–449, ISSN 0885-8950.
- PARK, Y., PARK, J. (1989). An expert system for short-term load forecasting by fuzzy decision. *Proceedings of Second Symposium on Expert Systems Application to Power Systems (ESAPS)*, p. 244–50, Seattle, July, 1989.
- PELIKÁN, E. (2002). Middle-Term Electric Load Forecasting by Time Series Decomposition. In *Electricity Load Forecast using Intelligent Technologies*, (Ed.: Slinčák P., Strackeljan J., Kolcun M., Novotný D., Szathmáry P.), pp. 167-176, ISBN 80-89066-41-0, ELFA Košice, 2002.
- RAHMAN, S, BHATNAGAR, R. (1988). An expert system based algorithm for short term load forecast. *IEEE Transaction on Power Systems*, Volume 3, Issue 2, May 1988, pages 392–9, ISSN 0885-8950.
- RAMANATHAN, R., ENGLE, R., GRANGER, C.W.J., VAHIDARAGHI, F., BRACE, C. (1997). Short run forecasts of electricity loads and peaks. *International Journal of Forecasting*, Volume 13, Issue 2, Jun 1997, pages 161–174, ISSN 0169-2070.
- RANAWEERA, D., HUBELE, N., KARADY, G. (1996). Fuzzy logic for short term load forecasting. *International Journal of Electrical Power & Energy Systems*, Volume 18, Issue 4, May 1996, pages 215–222, ISSN 0142-0615.
- SADOWNIK, R., BARBOSA, E.P. (1999). Short-term forecasting of industrial electricity consumption in Brasil. *Journal of Forecasting*, Volume 18, Issue 3, May 1999, pages 215–224.

- SIMON, H. (1994). *Neural Networks, A Comprehensive Foundation*. Macmillan, New York, USA.
- SMITH, M. (2000). Modeling and short-term forecasting of New South Wales electricity system load. *Journal of Bussines and Economic Statistics*, Volume 18, 2000, pages 465–478.
- SOLIMAN, S.A., PERSAUD, S., EL-NAGAR, K., EL-HAWARY, M.E. (1997). Application of list absolute value parameter estimation based on linear programming to short-term load forecasting. *International Journal of Electrical Power & Energy Systems*, Volume 19, Issue 3, March 1997, pages 209–216, ISSN 0142-0615.
- SRINIVASAN, D. (1998). Evolving artificial neural networks for short term load forecasting. *Neurocomputing*, Volume 23, Issue 1-3, December 1998 ,pages 265-276, ISSN 0925-2312.
- TAKENAWA, T., SCHNEIDER, A.M., SCHIFFMAN, D.A. (1980). A computer program for 24-hour electric utility load forecasting. *Energy*, Volume 5, Issue 7, July 1980, Pages 571-585, ISSN 0360-5442.
- TAMIMI, M., EGBERT, R. (2000). Short term electric load forecasting via fuzzy neural collaboration. *Electric Power Systems Research*, Volume 56, Issue 3, December 2000, pages 243–248, ISSN 0378-7796
- TSOI, A.C., KOBE, M.U. (1983). Load forecasting in a power system from a supply authority point of view. *Electric Power Systems Research*, Volume 6, Issue 2, pages 147-159, ISSN 0378-7796.
- WIKLUND, H. (1991). Short term forecasting of the heat load in a DH-system. *Fernwaerme International*, Volume 20, Issue 5-6, May - June 1991, ISSN 0933-6540.
- YANG, H.T., HUANG, C.M. (1998). A new short-term load forecasting approach using self-organizing fuzzy ARMAX models. *IEEE Transaction on Power Systems*, Volume 13, Issue 1, February 1998, pages 217–225, ISSN 0885-8950.
- YANG, H.T., HUANG, C.M., HUANG, C.L. (1995). Identification of ARMAX model for short term load forecasting: an evolutionary programming approach. *Proceedings of the*

- IEEE Power Industry Computer Applications Conference (PICA)*, pages 325–330, Salt Lake City, USA, May, 1995.
- YAO, S.J., SONG, Y.H., ZHANG, L.Z., CHENG, X..Y. (2000). Wavelet transform and neural networks for short-term electrical load forecasting. *Energy Conversion and Management*, Volume 41, Issue 18, December 2000, pages 1975–88, ISSN 0196-8904.
- ZADEH, L.A., DUBOIS, D., PRADE, H.M. (2000). *Fundamentals of fuzzy sets*. Kluwer Academic Publisher, ISBN 0-7923-7732-X. Boston. USA.
- ZHANG, B.L., DONG, Z.Y. (2001). An adaptive neural-wavelet model for short term load forecasting. *Electric Power System Research*, Volume 59, Issue 2, September 2001, pages 121–129, ISSN 0378-7796.
- ZHANG, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, Volume 50, January 2003, pages 159-175.
- ŽÁK, L. (2002). Odhad vlivu počasí na odběr elektrické energie pomocí fuzzy regulátoru, *Automatizace č.5-6/2002*, str. 326-330, ISSN 0005-125X

PŘÍLOHY

Příloha A: Reálná data odběrů tepla a venkovní teploty z lokality Zlínka.

Příloha B: Reálná data odběrů tepla a venkovní teploty z lokality Olomoucka.

Příloha C: Seznam M-souborů

Pozn: Data byla získána s periodou 30 minut a pochází z období 1.11.1998-25.11.1998.
První a třetí řádek u daného datumu představuje odběr tepla v t/hod, druhý a čtvrtý řádek obsahuje hodnotu venkovní teploty ve °C.

Příloha C: Seznam M-souborů

box_jen.m, cubic.m, cubicfce.m, delka_pr.m, dv_filt.m, dvoji_f.m, edit.m, graf.m, graf_teploata.m, graf_zaloha.m, historie.m, hlaseni.m, hlaska.m, hlaska2.m, hlaska3.m, kalendar.m, kontrola_zahr.m, kontrola_zahr_cubic.m, kontrola_zahr_linear.m, linear.m, linearfce.m, loading.m, menu.m, meteo.m, mutual_exclude.m, param.m, param_opt.m, parametry.m, pasmo.m, perioda.m, poloha_minima.m, soubor.m, st_hodn.m, start.m, sup_vyp.m, superpoz.m, uloz.m, vyhlazeni.m, vyp_vysl.m, vyp_vysl_konec.m, vypocet.m, vysled_dopredu.m, vysled_zpet.m, w_prekr.m, zobraz.m, zobraz_edit.m,