

Západočeská univerzita v Plzni  
Fakulta aplikovaných věd  
Katedra kybernetiky

## Diplomová práce

Regulační potřeby provozovatele přenosové sítě v  
podmínkách nárůstu obnovitelných zdrojů elektrické energie

Plzeň, 2012

Perný Adam

## PROHLÁŠENÍ

Předkládám tímto k posouzení a obhajobě diplomovou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem příloženou diplomovou práci vypracoval samostatně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne .....

.....

*Vlastnoruční podpis*

## PODĚKOVÁNÍ

Chtěl bych poděkovat všem, kteří mi přímo či nepřímo pomáhali při vzniku této práce. Zvláště pak děkuji panu Doc. Ing. Eduardu Janečkovi CSc., vedoucímu mé Diplomové práce.

Především ale děkuji rodičům a celé své rodině, protože mi v průběhu studia poskytovali zázemí a veškerou podporu hmotnou i duševní.

## ANOTACE

Tato práce se zabývá analýzou současné situace v oblasti predikce výroby elektrické energie z obnovitelných zdrojů, konkrétně z fotovoltaických zdrojů, a způsoby regulace odchylek výroby z těchto zdrojů za účelem minimalizovat ztrát.

V praktické části práce se pokusíme navrhnout prakticky použitelný prediktor výroby elektrické energie z fotovoltaických elektráren, který vychází z aktuálního stavu a dlouhodobých trendů. Tento prediktor má sloužit k rychlé a aktuální predikci na krátkou dobu.

## ANNOTATION

This work deals with analyzing the current situation of the prediction of electricity production from renewable sources, namely from photovoltaic systems, and methods of deviations control of production from these sources in order to minimize losses.

In the practical part of the work we will try to propose a practically usable predictor of power for prediction of electricity production of photovoltaic systems, which is based on the current state and long-term trends. This predictor is used to fast and the current forecast for short time.

# Obsah

<b>1. ÚVOD.....</b>	<b>7</b>
<b>2. PODPŮRNÉ SLUŽBY .....</b>	<b>11</b>
2.1. STRUČNÝ POPIS .....	11
2.2. PŘEHLED ZÁKLADNÍCH PODPŮRNÝCH SLUŽEB (PPS) .....	12
2.2.1. <i>Primární regulace frekvence bloku</i> .....	13
2.2.2. <i>Sekundární regulace výkonu bloku</i> .....	13
2.2.3. <i>Minutová regulační záloha pro terciární regulaci výkonu</i> .....	13
<b>3. POUŽITÁ DATA .....</b>	<b>14</b>
3.1. PŘEDPOVĚĎ POČASÍ .....	14
3.2. VYROBENÁ ELEKTRICKÁ ENERGIE Z FVE .....	15
3.3. POUŽITÝ MATEMATICKÝ APARÁT .....	16
3.4. ZÁKLADY STATISTIKY .....	16
3.4.1. <i>Náhodná veličina</i> .....	16
3.4.2. <i>Stochastický proces</i> .....	16
3.4.3. <i>Střední hodnota</i> .....	17
3.4.4. <i>Rozptyl</i> .....	17
3.4.5. <i>Směrodatná odchylka</i> .....	18
3.4.6. <i>Modus</i> .....	18
3.4.7. <i>Stacionarita</i> .....	18
3.4.8. <i>Autoregresní model procesu</i> .....	19
3.4.9. <i>Markovův proces</i> .....	19
3.4.10. <i>Denní diagram</i> .....	20
3.5. PREDIKCE PARAMETRŮ .....	20
3.5.1. <i>Metoda nejmenších čtverců</i> .....	20
3.5.2. <i>Yule-Walkerovy rovnice</i> .....	22
<b>4. ANALÝZA DAT .....</b>	<b>25</b>
4.1. ZÍSKÁNÍ DENNÍCH DIAGRAMŮ .....	27
4.2. DENNÍ DIAGRAM PRO CELÝ ROK A VŠECHNY TŘÍDY OBLAČNOSTI.....	27
4.2.1. <i>Denní diagramy pro jednotlivé třídy oblačnosti</i> .....	32
4.2.2. <i>Denní diagramy pro jednotlivá období</i> .....	34

4.2.3.	<i>Výpočet denních diagramů pro období a třídy oblačnosti.....</i>	36
<b>5.</b>	<b>MODELOVÁNÍ VÝROBY Z FVE .....</b>	<b>38</b>
5.1.	ODSTRANĚNÍ PROMĚNLIVÉ VELIKOSTI SMĚRODATNÉ ODCHYLKY BĚHEM DNE .....	38
5.2.	MODELOVÁNÍ AR PROCESU .....	40
5.3.	MODELOVÁNÍ MARKOVOVA MODELU PŘECHODŮ MEZI JEDNOTLIVÝMI TŘÍDAMI.....	40
5.4.	PREDIKCE VYROBENÉ ELEKTRICKÉ ENERGIE Z FVE.....	44
5.5.	CHYBA PREDIKCE.....	45
5.5.1.	<i>Varianta „horší“ počasí .....</i>	<i>46</i>
5.5.2.	<i>Varianta „lepší“ počasí.....</i>	<i>48</i>
5.5.3.	<i>Citlivost chyby predikce na velikost instalovaného výkonu.....</i>	<i>50</i>
5.5.4.	<i>Denní diagramy chyby predikce .....</i>	<i>51</i>
5.6.	VLIV CHYBY PREDIKCE NA REGULAČNÍ ODCHYLKU ACEO .....	53
5.7.	VÝŠE REGULAČNÍCH ZÁLOH.....	54
<b>6.</b>	<b>MOŽNÁ VYLEPŠENÍ .....</b>	<b>55</b>
<b>7.</b>	<b>ZÁVĚR.....</b>	<b>56</b>
<b>8.</b>	<b>POUŽITÉ ZDROJE .....</b>	<b>57</b>

# 1. Úvod

Cílem této práce je na základě analýzy současné situace navrhnout prediktor výroby elektrické energie z fotovoltaických elektráren za účelem snížení nutného množství podpůrných služeb provozovatele přenosové sítě. V důsledku nedávného nárůstu instalovaného výkonu těchto zdrojů, roste i potřeba se touto problematikou zabývat.










Na úvod této práce tedy uvedme několik důvodů, proč se touto problematikou zabývat a několik základních informací pro snazší orientaci v následujícím textu.

Výroba elektrické energie z obnovitelných zdrojů, je závislá na přírodních podmínkách. V případě fotovoltaických systémů (dále FVE) je tím zásadním faktorem osvit, ten je fotometrická veličina, definovaná jako plošná hustota světelného množství, které dopadlo na danou plochu v časovém intervalu (osvětlení  $E$  v čase  $t$ ). Značí se  $H$ ,  $H = E \cdot t$ . Její jednotkou je *lux · sekunda* ( $lx \cdot s$ ).

Na osvit má největší vliv roční období, respektive vzájemná pozice Slunce a Země a míra oblačnosti. Důležitou složkou predikce tedy bude aktuální stav a předpověď počasí.

V meteorologické terminologii se udává míra oblačnosti slovně, podle osmin pokrytí oblohy viz následující tabulka.

Tab. 1.1 předpověď oblačnosti

pokrytí oblohy [v osminách]	význam	značka	astronomický svit [%]
0	jasno		100%
1	skoro jasno		61% - 100%
2			
3	polojasno		31% - 60%
4			
5	oblačno		11% - 30%
6			
7	skoro zataženo		0% - 10%
8	zataženo		

(zdroj: <http://cs.wikipedia.org/wiki/Oblačnost> [1])

Velký vliv má také úhel pod jakým dopadá sluneční záření na plochu FV panelu, to je zřejmé i ze vzorce pro osvit, který lze v případě bodového zdroje o svítivosti  $I$  a paprsků dopadajících pod úhlem  $\alpha$  k normále plochy, vzdálené od zdroje  $r$  upravit:

$$E = \frac{I}{r^2} \cos \alpha \quad [lux]$$

Osvětlení  $E$  (a tím i osvit) je tedy tím slabší, čím šikměji paprsky dopadají.

Vliv mají i další veličiny, jako je teplota, vzdušná vlhkost a samozřejmě znečištění panelu FV prachem, pylem nebo sněhem a podobně.

(zdroj: <http://cs.wikipedia.org/wiki/Osvětlivost> [2])

Z předchozího je patrné, že fotovoltaický systém může dosáhnout maximálního (instalovaného výkonu ve  $W_p$ , viz níže) jen po krátkou dobu (dané úhlem – většinou se panely instalují pod úhlem, aby maximum nastalo mezi 12. a 13. hodinou, kdy má i sluneční záření maximální intenzitu) a to jen při ideálním stavu atmosféry (ovlivňuje intenzitu, ale i



složení slunečního záření) a nulové oblačnosti. Samozřejmě roli hraje roční období (resp. trajektorie slunce na obloze a maximální intenzita slunečního záření). Je tedy jasné, že důležitým faktorem pro predikci výroby z těchto zdrojů je znalost právě těchto informací – očekávaný výkon zjistíme analýzou dlouhodobých trendů (např. rozdělíme dny podle ročních období a děláme trendy pro jednotlivá období, nebo můžeme dělat trendy pro každý kalendářní den, týden, atd.), tento trend poté korigujeme na základě aktuálních dat (výroba za poslední časový úsek, předpověď počasí...)

Výkon FV se uvádí ve Wp (watt peak, případně násobky), kde Wp je jednotkou špičkového výkonu dodávaného solárním zařízením za ideálních podmínek. Jde o výkon vyrobený solárním panelem při standardizovaném výkonnostním testu, tedy při energetické hustotě záření  $1000\text{Wm}^2$ ,  $25^\circ\text{C}$  a světelném spektru odpovídajícím slunečnímu záření po průchodu bezoblačnou atmosférou Země.

(zdroj: <http://www.zkratky.cz/Wp/16927> [3]).

Základní problém s FV je, že se nelze na tento zdroj elektřiny zcela spolehnout, nedá se dlouhodobě, s dostatečnou přesností, předpovědět výkon a to ani několik dní dopředu. Je tedy nutné mít stále záložní zdroj elektrické energie v případě výpadku výroby z tohoto zdroje a to realizují Podpůrné služby. Potřebné množství těchto služeb lze minimalizovat, pokud navrheme takový prediktor, aby byl schopný co nejpřesněji předpovědět výrobu z FV (alespoň krátkodobě) na základě statistických a aktuálních informací.

Dalším problémem FV je nízká účinnost přeměny slunečního záření na elektrickou energii fotovoltaických panelů. V současnosti jsou téměř všechny panely vyráběné z krystalického nebo polykrystalického křemíku, protože křemíkové technologie jsou v současné době nejlépe zvládnuté kvůli rozmachu polovodičových technologií. U současných tenkovrstvých článků dosahuje účinnost přibližně 8% - 9%, časem se však snižuje mnohem rychleji než u tlustovrstvých článků, těch je více než 85% solárních článků na trhu, jejich účinnost je ale znatelně nižší. Ale už se hledají způsoby, jak tento nepříznivý fakt odstranit. V roce 2006 Národní laboratoř pro obnovitelnou energii (USA) představila články využívající trojnásobné přechody s efektivitou až 40,7%. Také se zkoumají i nekřemíkové technologie. Na rozdíl od předešlých se pro konverzi světla na elektrickou energii nepoužívá tradiční P-N polovodičový přechod, ale různé organické sloučeniny, polymery atd. (tyto technologie jsou většinou ve stádiu výzkumu). Vzhledem k možnému masovému využití fotovoltaických článků, jejichž výrobní cena by byla podstatně nižší než v současnosti, probíhá také výzkum fotovoltaických článků pracujících s jinými fotocitlivými materiály než je

křemík. Jednou z možností jsou vodivé polymery; např. v listopadu 2005 se podařilo výzkumné skupině na University of California v Los Angeles dosáhnout zatím maximální účinnosti 4,4%.

(zdroj: [http://cs.wikipedia.org/wiki/Fotovoltaický\\_článek](http://cs.wikipedia.org/wiki/Fotovoltaický_článek) [4])


## 2. Podpůrné služby

V této kapitole zavedeme důležité pojmy pro porozumění hlavní problematice práce, vycházíme ze zdrojů [5], [6] a [7]

### 2.1. Stručný popis

Roli provozovatele přenosové sítě (PPS) při zajištění výkonové rovnováhy v elektrizační soustavě (ES) ukazuje Obr. 2.1 a Obr. 2.2 PPS aktivuje v případě potřeby regulační zálohy, které si musí v předstihu obchodně zajistit a to ve formě podpůrných služeb (PpS).

Obr. 2.1 Principiální schéma regulace činných výkonů na úrovni PPS bez uvažování vlivu frekvence



Na Obr. 2.1 předpokládáme, že od měření A, B a C je odečten výkon solidární primární regulace na blocích a proto v tomto velmi zjednodušeném schématu chybí regulační obvody systémové frekvence na blocích i u provozovatele přenosové soustavy.

Jednou z možností jak zajistit spolehlivý provoz ES je plánovat regulační zálohy v takové výši, aby se soustava chovala tak jako v minulých letech, kdy nebyly hlášeny žádné

mimořádné stavy, až na výjimky dané podmínkami provozu okolních soustav, a soustava byla považována za spolehlivou. Vyloučíme-li z časové řady ACE zmíněné kritické dny, pak budou hodnoty ukazatelů spolehlivosti vypočítané z historických dat ACE limitem, který nemá být překročen. Regulační zálohy naplánujeme v takové výši, aby k překročení limitních hodnot ukazatelů spolehlivosti nedošlo.

Z předchozího vyplývá, že podpůrné systémy (PpS) jsou záložní zdroje elektrické energie, které se aktivují v případě výpadku výroby (poruchy) nebo nečekaného nárůstu spotřeby.

Je tedy jasné, že čím větší množství PpS je zapotřebí, tím roste jejich cena a zároveň, čím větší množství vyrobené energie pochází z hůře předvídatelných zdrojů, jako jsou větrné nebo právě fotovoltaické elektrárny, tím větší množství PpS je zapotřebí nakoupit z důvodu větší pravděpodobnosti výpadku.

## 2.2. Přehled základních Podpůrných služeb (PpS)

Podle rychlosti náběhu potřebného výkonu se PpS rozdělují do několika kategorií.

Primární regulace frekvence bloku (PR)

Sekundární regulace výkonu bloku (SR)

Terciální regulace výkonu bloku (TR)

Rychle startující 10-ti a 30-ti minutová záloha (QS\_10 a QS\_30)

Dispečerská záloha (DZ a DZ\_90)

S platností od roku 2013 budou některé PpS nahrazeny, nově budou definovány tyto kategorie PpS:

regulační záloha pro primární regulaci frekvence (PpS PR)

regulační záloha pro sekundární regulaci frekvence a výkonu (PpS SR)

minutová regulační záloha (PpS MZ a to MZ5 a MZ15)

regulační zálohy snížení výkonu (PpS SV30)

### **2.2.1. Primární regulace frekvence bloku**

Primární regulace bloku je lokální automatická funkce zajišťovaná obvody primární regulace. Automatická funkce spočívá v přesně definované změně výkonu elektrárny v závislosti na odchylce frekvence od zadané hodnoty.

Poskytovatel PpS (primární regulace) musí zajistit uvolnění regulační zálohy do 30 vteřin od vzniku odchylky frekvence. Maximální rezervovaná regulační záloha se uvolňuje již při odchylce 200 mHz.

### **2.2.2. Sekundární regulace výkonu bloku**

Sekundární regulace výkonu bloku slouží ke změně výkonu regulovaného elektrárenského bloku, tak jak je požadováno sekundárním regulátorem frekvence a salda předávaných výkonů. Využití regulační zálohy je dáno algoritmem sekundárního regulátoru dispečinku ČEPS. Sekundární regulace probíhá automaticky, požadavky jsou rozesílány prostřednictvím optické linky. Poskytovatel PpS (sekundární regulace) musí zajistit uvolnění regulační zálohy do sítě maximálně během 10 minut od požadavku. Rychlost změny výkonu by měla být minimálně 2 MW/min.

### **2.2.3. Minutová regulační záloha pro terciární regulaci výkonu**

Minutová regulační záloha je využívána v rámci terciární regulace činného výkonu. Slouží ke změně výkonu bloku na základě požadavku, který přichází do elektrárny od Dispečinku ČEPS. Poskytovatel PpS poskytuje tuto službu jako:

MZ5 - pětiminutovou zálohu, kdy požadované změny výkonu musí být dosaženo do 5 minut,

MZ15 - patnáctiminutovou zálohu, kdy požadované změny výkonu musí být dosaženo do 15 minut.

## 3. Použitá data

### 3.1. Předpověď počasí

V programu nemůžeme použít přímo osminy pokrytí oblohy podle (Tab. 1.1), protože máme pouze slovní předpověď, takže musíme použít kódy pro všechny možné případy, viz následující tabulka:

*Tab. 3.1 kódy předpovědí*

kód	stupeň pokrytí oblohy (předpověď)	pokrytí oblohy v osminách (měření)
1	jasno	0/8
2	skoro jasno	1/8 až 2/8
3	polojasno	3/8 až 4/8
4	oblačno	5/8 až 6/8
5	skoro zataženo	7/8
6	zataženo	8/8
0	bez udání	
9		nelze rozeznat (mlha)
10		automat (nelze stanovit)

Naměřená data i data z předpovědi byla zakódována dle uvedené tabulky (Tab. 2.1). U predikce budeme mimo jiné používat předpověď oblačnosti, proto budeme pracovat pouze se šesti třídami (1 – 6). Třídy 0, 9, 10 jsou pro nás nepoužitelné, bez předpovědi počasí musíme hledat náhradu pro aktuální předpověď – použít starší předpověď pro aktuální den (z minulého dne, je-li k dispozici)

Použita jsou meteorologická data z Českého hydrometeorologického institutu (<http://www.chmi.cz/>) a to od 1. 4. 2011

Předpověď počasí (slovní označení stupně pokrytí pro kraje, granulita = den)

Naměřená data (hodinová data pokrytí v osminách v 39 lokalitách po celé ČR)

## 3.2. Vyrobená elektrická energie z FVE

Data výroby elektrické energie za celou ČR (souhrnné) jsou od 1. 4. 2011. Data jsou hodinové průměry a lze je najít na adrese:

<http://www.ceps.cz/CZE/Data/Vsechna-data/Stranky/Vyroba.aspx>

Pro vytvoření modelu a následný návrh prediktoru je použita vyrobená elektrická energie z ČVUT - jsou použita data také od 1. 4. 2011, viz [http://andrea.feld.cvut.cz/fvs\\_](http://andrea.feld.cvut.cz/fvs_)

Data jsou normována pomocí instalovaného výkonu - u dat z ČVUT jsou hodnoty napsány na výše zmíněném webu, u dat za celou ČR použijeme hodnoty ze stránek [www.eru.cz](http://www.eru.cz) (-> Elektřina -> statistika -> bod 42, hodnoty instalovaného výkonu FVE za celou ČR)

Z tohoto webu ([www.eru.cz](http://www.eru.cz) -> Elektřina -> statistiky -> bod 49) získáme také instalované výkony FVE za jednotlivé kraje, v tabulce jsou uvedeny procenta instalovaného výkonu k prosinci 2011.

*Tab. 3.2 poměrné zastoupení instalovaného výkonu FVE*

REAS	kraj	procento instalovaného výkonu
JME - E.ON Východ	Vysočina, Jihomoravský, Zlínský	34%
JČE - E.ON Západ	Jihočeský	12%
SME - ČEZ Morava	Olomoucký, Moravskoslezský	8%
SCE - ČEZ Sever	Ústecký, Liberecký	14%
STE - ČEZ Střed	Středočeský	12%
VCE - ČEZ Východ	Královéhradecký, Pardubický	8%
ZCE - ČEZ Západ	Karlovarský, Plzeňský	11%
PRE – PREdi	Praha	1%

Zde získáme poměrné rozložení FVE po republice, to je použito později. Musíme totiž pracovat s předpověďmi počasí pro jednotlivé kraje a z nich získat vážený průměr pro předpověď pro celou ČR.

### 3.3. Použitý matematický aparát

V této kapitole zavedeme některé důležité pojmy a vztah z pravděpodobnosti a statistiky. Tyto znalosti jsou pak použity pro statistickou analýzu naměřených dat. Následující pojmy jsou čerpány z [8], [9] a [10].

### 3.4. Základy statistiky

#### 3.4.1. Náhodná veličina

může reprezentovat např. měření, pokusy, výrobní procesy apod., se kterými se setkáváme v praxi, ty lze z hlediska pravděpodobnosti výskytu určitého výsledku považovat za náhodné jevy, při nichž výsledek není jednoznačně určen výchozími podmínkami. V těchto případech je možno považovat naměřené hodnoty za hodnoty nějaké funkce definované na množině  $\Omega$  všech možných jevů. Tato funkce se nazývá náhodná veličina a budeme ji zpravidla značit  $X$ . Pro funkční hodnoty náhodné veličiny budeme používat název realizace náhodné veličiny a budeme je označovat malými písmeny  $x, y$  (případně s indexy).

#### 3.4.2. Stochastický proces

je v čase uspořádaná řada náhodných veličin  $\{X(s, t), s \in S, t \in T\}$ , kde  $S$  je prostor výběru a  $T$  je řada indexů. Pro každé  $t \in T$  je  $X(., t)$  náhodná veličina definovaná na prostoru výběru  $S$ . Pro každé  $s \in S$  je  $X(s, .)$  realizace stochastického procesu definovaná na indexní řadě  $T$ , tj. uspořádaná řada čísel, z níž každé odpovídá jedné hodnotě řady indexů. Časovou řadu lze tedy považovat za realizaci stochastického procesu. V dalším textu budeme předpokládat, že řada indexů je řadou čísel a uvažovaný stochastický proces má nespojitý charakter. Pro zjednodušení se bude stochastický proces značit stejně jako jeho realizace, tedy časová řada jako  $X_t$ . Z kontextu je zřejmé, zda se jedná o stochastický proces nebo časovou řadu.



### 3.4.3. Střední hodnota

náhodné veličiny  $X$ , označovaná  $\mu$  nebo  $E(X)$ , je reálné číslo definované pro diskrétní náhodnou veličinu, která nabývá hodnot  $x_1, x_2, \dots$  s pravděpodobnostmi  $p_1, p_2, \dots$ , tj.  $[P(X = x_i) = p_i]$  takto:

$$\mu = E(X) = \sum_i x_i p_i = x_1 p_1 + x_2 p_2 + \dots \quad (3.1)$$

Střední hodnota je za určitých předpokladů limitním případem aritmetického průměru realizací náhodné veličiny. Aritmetický průměr lze tedy považovat pro velký počet hodnot za dobrý odhad střední hodnoty.

Střední hodnota je tedy počítána ze vztahu:

$$\hat{\mu} = \frac{1}{N} \sum_i x_i, \quad (3.2)$$

kde  $N$  je počet realizací, kterých nabývá náhodná veličina  $X$ .

Obdobně lze definovat pro spojité veličiny, vyjdeme z rovnice (2.1) a limitním přechodem nahradíme sumu integrálem. V této práci však budeme pracovat výhradně s diskrétními veličinami.

### 3.4.4. Rozptyl

náhodné veličiny  $X$ , píšeme  $D(X)$  nebo  $\sigma^2$ , je reálné číslo definované předpisem:

$$\sigma^2 = D(X) = (X - E(X))^2 \quad (3.3)$$

Z definice odvozujeme tzv. výpočetní tvar rozptylu ve tvaru:

$$\sigma^2 = D(X) = E(X^2) - E^2(X) \quad (3.4)$$

Odhad rozptylu diskrétní veličiny lze počítat například podle výpočetního vztahu:

$$\hat{\sigma}^2 = \frac{1}{N} \sum_i x_i^2 - \hat{\mu}^2 \quad (3.5)$$

kde  $N$  je počet realizací, kterých nabývá náhodná veličina  $X$ .

### 3.4.5. Směrodatná odchylka

náhodné veličiny  $X$ , označována jako  $\sigma$ , je definována jako druhá odmocnina z rozptylu:

$$\sigma = \sqrt{D(X)} \quad (3.6)$$

### 3.4.6. Modus

náhodné veličiny  $X$ , označovaný  $mod(X)$ , je definován jako nejčastěji zastoupená realizace  $X(., t)$  pro každé  $t \in T$ . V případě použití funkce modus je nutné zvážit ošetření situace, když je nejčastěji vyskytujících se prvků více.

### 3.4.7. Stacionarita

Stochastický proces se nazývá striktně stacionární, jestliže pro jakoukoliv indexní část  $(t_1, t_2, \dots, t_n)$  z  $T = \{0, \pm 1, \pm 2, \dots\}$  a jakékoliv reálné číslo  $k$ , pro které  $t_i + k \in T$ ,  $i = 1, 2, \dots, n$ , platí:

$$F(X_{t_1}, X_{t_2}, \dots, X_{t_n}) = F(X_{t_1+k}, X_{t_2+k}, \dots, X_{t_n+k}) \quad (3.7)$$

kde  $F(.)$  je sdružená distribuční funkce.

Striktní stacionarita tedy říká, že pravděpodobnostní chování daného stochastického procesu je časově invariantní.

Stochastický proces se nazývá slabě stacionární, pokud první a druhý moment (střední hodnota a rozptyl) náhodné veličiny  $X$  jsou pro každou indexní část  $(t_1, t_2, \dots, t_n)$  z  $T = \{0, \pm 1, \pm 2, \dots\}$  a jakékoliv reálné číslo  $k$ , pro které  $t_i + k \in T$ ,  $i = 1, 2, \dots, n$ , stejné.

V praktické analýze časových řad se operuje výhradně se slabou stacionaritou, neboť je relativně snadné odhadovat první dva momenty. V případě, že budeme mluvit o stacionaritě, budeme mít na mysli výhradně stacionaritu slabou.

### 3.4.8. Autoregresní model procesu

je model stacionárních časových řad, kde aktuální hodnota  $x_t$  je funkcí předchozích hodnot  $x_{t-1}, x_{t-2}, \dots, x_{t-n}$ , kde  $n$  určuje řád systému (modelu):


$$x_t = k_0 + k_1 x_{t-1} + k_2 x_{t-2} + \dots + k_n x_{t-n}$$

### 3.4.9. Markovův proces

Poskytují matematický prostředek pro modelování stacionárních náhodných procesů, kdy jsou výsledky náhodné. V každém okamžiku je systém ve stavu  $s$  a poté přejde do náhodného stavu  $s'$ . Přitom pravděpodobnost, že proces přejde do stavu  $s'$  závisí na předchozím stavu  $s$ .

Pravděpodobnost je určena funkcí přechodu  $P(s, s')$ , dané  $s$  je však podmíněně závislé na předchozích stavech  $\Rightarrow$  Markovská vlastnost.

Obr. 3.1 Model Markovského procesu



Na obrázku (Obr. 3.1) je znázorněn jednoduchý model Markovova procesu. Mezi všemi stavy je možné přecházet s pravděpodobnostmi danou funkcí přechodu nebo ve stavu setrvat. Určité přechody však mohou být principiálně nemožné (např.  $P(s'', s') = 0$ ). V souvislosti se setrváním ve stavu mluvíme o střední době setrvání, ta je střední hodnotou

času (pro diskrétní veličiny počet vzorků) stráveného v jednom stavu (většinou se předpokládá normální rozložení pravděpodobnosti).

### 3.4.10. Denní diagram

je typický denní průběh sledovaného signálu. V našem případě se jedná o výrobu elektrické energie. Dále budeme určovat denní diagramy pro určitou třídu. Třídy mohou být podle ročních období (východů a západů slunce, měsících...) a podle třídy oblačnosti (viz Tab. 2.2).

K získání denních diagramů můžeme použít střední hodnotu, modus, maximum apod. ze všech realizací náhodné proměnné  $X(., t)$  pro všechna  $t \in T$ , kde  $T$  reprezentuje čas v rámci jednoho dne (vzhledem k tomu, že v noci bude výroba nulová, nebudeme pracovat s celým dnem).

Denní diagramy zde budou sloužit jako první odhad výroby elektrické energie, který bude poté upřesněn.

## 3.5. Predikce parametrů

V této kapitole uvedeme identifikační metody, které je možné použít pro návrh prediktoru, lze je nalézt v [6].

### 3.5.1. Metoda nejmenších čtverců

Tato metoda je asi nejjednodušší identifikační metoda, kterou lze použít. Pro aplikaci lineární regrese na dynamické modely bude uvažováno:

$$A(q^{-1})y(t) = e(t), \quad (3.7)$$

kde

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_{na} q^{-na}.$$

V (2.26) člen  $e(t)$  označuje chybu rovnice. Model systému lze ekvivalentně vyjádřit jako

$$y(t) = \varphi^T(t)\Theta + e(t), \quad (3.8)$$

kde

$$\varphi^T(t) = (-y(t-1)\dots - y(t-na))$$

$$\Theta = (a_1 \dots a_{na})$$

Optimální odhad parametrů ve smyslu minimalizace kritéria

$$V_N(\Theta) = \frac{1}{N} \sum_{t=1}^N e^2(t), \quad (3.9)$$

je

$$\hat{\Theta} = \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t)\varphi^T(t) \right]^{-1} \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t)y(t) \right]. \quad (3.10)$$

Analýza odhadu (2.29) pro model (2.26), (2.27). Předpokládejme, že data splňují

$$A_0(q^{-1})y(t) = v(t), \quad (3.11)$$

nebo

$$y(t) = \varphi^T(t)\Theta_0 + v(t), \quad (3.12)$$

kde  $\Theta_0$  je vektor skutečných parametrů a  $\{v(t)\}$  je stacionární stochastický proces nezávislý se vstupním signálem. Jestliže odhad  $\hat{\Theta}$  je dobrý, měl by být blízko vektoru parametrů  $\Theta_0$ . Jak je to v tomto případě, se můžeme dozvědět výpočtem chyby odhadu.

Dostaneme

$$\begin{aligned} \hat{\Theta} - \Theta_0 &= \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t)\varphi^T(t) \right]^{-1} \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t)y(t) - \left\{ \frac{1}{N} \sum_{t=1}^N \varphi(t)\varphi^T(t) \right\} \Theta_0 \right] \\ &= \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t)\varphi^T(t) \right]^{-1} \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t) \{ \varphi^T \Theta_0 + v(t) \} - \left\{ \frac{1}{N} \sum_{t=1}^N \varphi(t)\varphi^T(t) \right\} \Theta_0 \right] \end{aligned} \quad (3.13)$$

$$= \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t) \varphi^T(t) \right]^{-1} \left[ \frac{1}{N} \sum_{t=1}^N \varphi(t) v(t) \right].$$

Nyní je zřejmé, že odhad  $\hat{\Theta}$  je konsistentní ( $\hat{\Theta} \rightarrow \Theta_0$ , když  $N \rightarrow \infty$ ), jestliže

$$E \varphi(t) \varphi^T(t) \text{ je regulární} \quad (3.14)$$

a

$$E \varphi(t) v(t) = 0 \quad (3.15)$$

Podmínka (2.33) je splněna v mnoha případech. Nicméně jsou případy, kdy tomu tak není, např. když data zcela neobsahují šum ( $v(t) \equiv 0$ ) a řád modelu je vybrán příliš vysoký (z toho vyplývá, že odhadované polynomy mají společné faktory).

Na rozdíl od (2.33), podmínka (2.34) ve většině případů splněna není. Pouze v případě, že  $v(t)$  je bílý šum se střední hodnotou nula, je (2.34) jistě splněno. Ale když  $v(t)$  není bílý šum, bude nejspíše korelován s minulými výstupy, protože  $y(t)$  závisí podle (2.30) na  $v(s)$  pro  $s \leq t$ . Pak (2.34) neplatí.

### 3.5.2. Yule-Walkerovy rovnice

Nechť je

$$A(q^{-1})y(t) = e(t), \quad (3.16)$$

kde

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_{na} q^{-na}.$$

$$Ee(t) = 0 \quad Ee(t)e(s) = \lambda^2 \delta_{t,s}$$

Dále definujeme

$$r_k \triangleq Ey(t)y(t-k) \quad k = 0, \pm 1, \pm 2, \dots \quad (3.17)$$

Nyní vynásobíme-li obě strany rovnice (2.35) veličinou  $y(t-k)$  a provedeme-li operaci ustředění, dostaneme

$$r_k + a_1 r_{k-1} + \dots + a_{na} r_{k-na} = 0 \quad \text{pro } k=1,2,\dots \quad (3.18)$$

To je soustava lineárních rovnic pro parametry  $\{a_i\}$  (koeficienty autoregresního polynomu). Rovnice (2.37) jsou nazývány Yule-Walkerovy rovnice. Zapišeme prvních  $m$  rovnic maticovým způsobem

$$Ra = -r \quad (3.19)$$

$$a = [1, a_1, a_2, \dots, a_{na}]^T$$

$$r = [r_1, r_2, \dots, r_m]^T$$

$$R = \begin{bmatrix} r_0 & \dots & r_{na} \\ \vdots & & \vdots \\ r_{na} & \dots & r_0 \end{bmatrix}$$

kde  $m \geq na$ .

Lze dokázat, že matice  $R$  má plnou hodnotu. Prvky kovarianční matice  $R$  a vektoru  $r$  lze odhadovat z množiny pozorování  $\{y(1), y(2), \dots, y(N)\}$ . Necht'  $\hat{R}$  a  $\hat{r}$  označují odhady  $R$  a  $r$ . Pak  $\hat{a}$  (odhad  $a$ ), dostaneme ze vztahu:

$$\hat{R}\hat{a} = -\hat{r} \quad (3.20)$$

a bude konsistentní. Dále pro:

$m = na$  je  $\hat{a}$  nazýván minimální Yule-Walkerův odhad

$m > na$  je přeuredený systém rovnic a musíme hledat  $\hat{a}$  ve smyslu nejmenších čtverců, splňující  $\|\hat{R}\hat{a} + \hat{r}\|_Q^2 = \min$ . V tomto případě  $\hat{a}$  je nazýván přeuredený Yule-Walkerův odhad. Odhad, který splňuje  $\|\hat{R}\hat{a} + \hat{r}\|_Q^2 = \min$  pro nějakou pozitivně definitní matici  $Q \neq I$ , je nazýván vážený přeuredený Yule-Walkerův odhad

Zřejmě se jedná o jistý typ korelační techniky. Jestliže totiž zapišeme  $\hat{R}$  a  $\hat{r}$  takto:

$$\hat{R} = \frac{1}{N} \sum_{t=1}^N \begin{bmatrix} y(t-1) \\ \vdots \\ y(t-m) \end{bmatrix} (y(t-1)\dots(y(t-na))) \quad (3.21)$$

$$\hat{r} = \frac{1}{N} \sum_{t=1}^N \begin{bmatrix} y(t-1) \\ \vdots \\ y(t-m) \end{bmatrix} y(t) \quad (3.22)$$

pak odhad  $\hat{a}$  může být interpretován jako odhad získaný technikou přídavné proměnné pro systém:

$$y(t) = -(y(t-1), \dots, y(t-na))a + e(t) \quad (3.23)$$

a vektor přídavné proměnné:

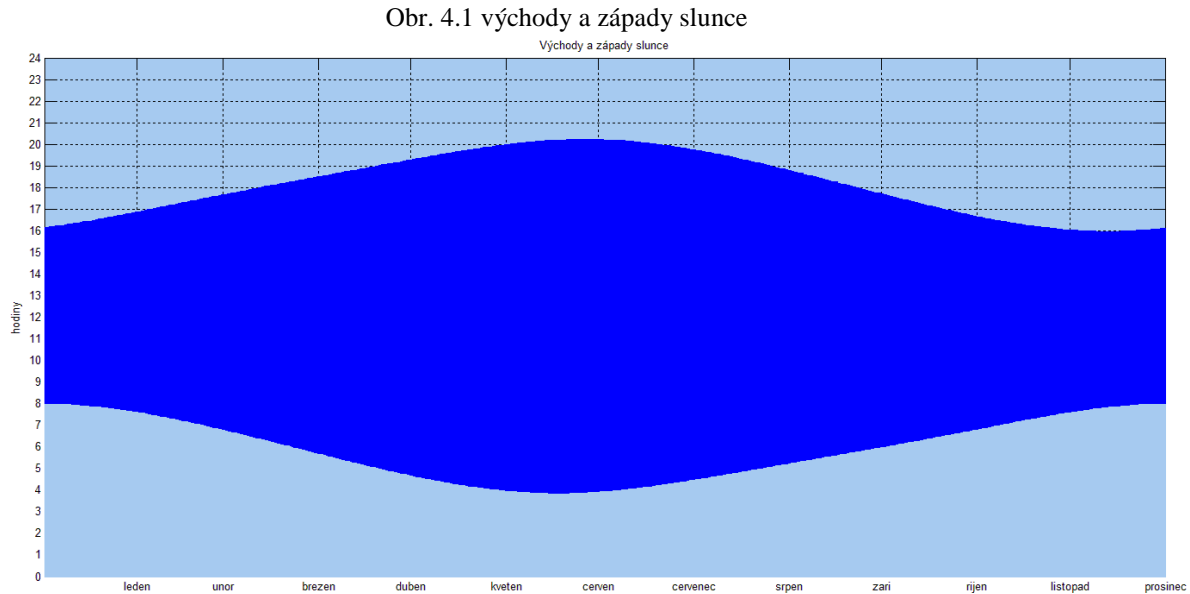
$$\zeta(t) = [-y(t-1), \dots, -y(t-m)]^T \quad (3.24)$$

Nevýhoda však je, že se nedozvíme, jaké jsou vlastnosti šumu.



## 4. Analýza dat

Pro výpočty použijeme data z ČVUT.



Na obrázku je modře vyznačen den od východu do západu slunce v roce 2010, čas je pro celý rok v SEČi.

Nyní musíme zvolit vhodný způsob rozdělení dat na třídy. Nabízí se možnost rozdělení po měsících, dále jsme uvažovali o variantě rozdělení podle východů a západů slunce (Obr. 4.1), pokud bychom vzali vždy rozmezí jedné hodiny rozdílu času východu slunce, získali bychom čtyři skupiny, má to ale několik nevýhod – jednotlivé skupiny nejsou stejně veliké a navíc dochází k drobnému posunu mezi roky.

Při bližším pohledu na obrázek (Obr. 4.1) je patrná podobnost křivky vyznačující východ a křivky vyznačující západ slunce a je patrné, že pokud bychom dělili do skupin podle času východu slunce a poté do skupin podle západu slunce nebyly by skupiny shodné. Nabízí se tedy varianta, kdy bychom rozdělovali do skupin podle délky dne.

My jsme se rozhodli pro rozdělení podle ročních období, konkrétně pro období:

10. 2. – 5. 5. – „jaro“

6. 5. – 5. 8. – „léto“

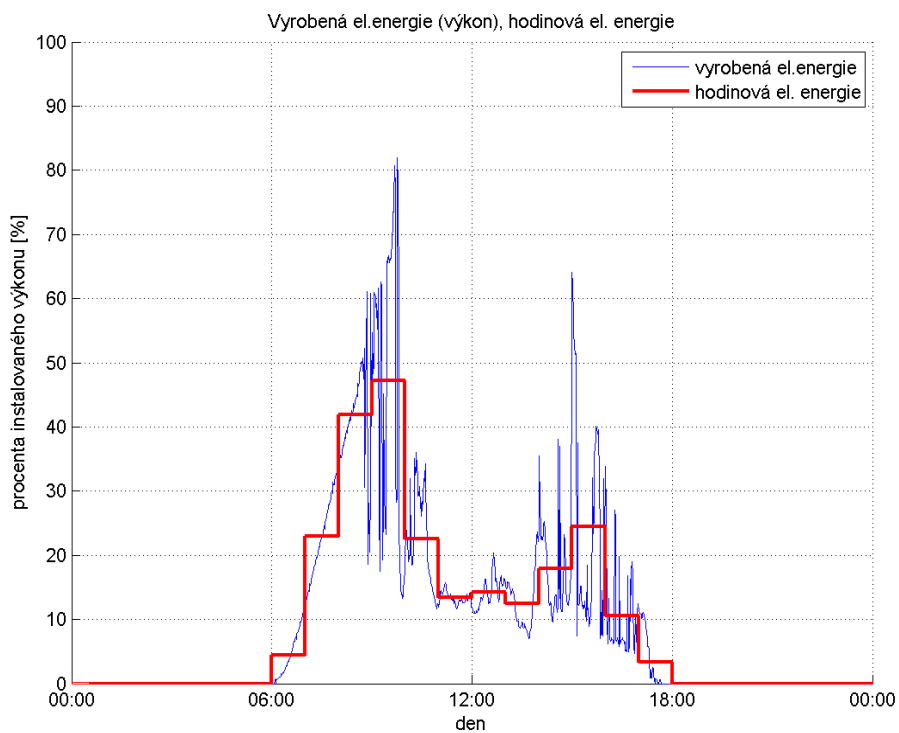
6. 8. – 5. 11. – podzim

6. 11. – 9. 2. – „zima“

toto rozdělení vychází i z časů východů a západů slunce, ale je pevné.

Nyní se čistě pro informaci podívejme na náhodně zvolený denní průběh:

*Obr. 4.2 Vyrobená elektrická energie 13. 9. 2011*



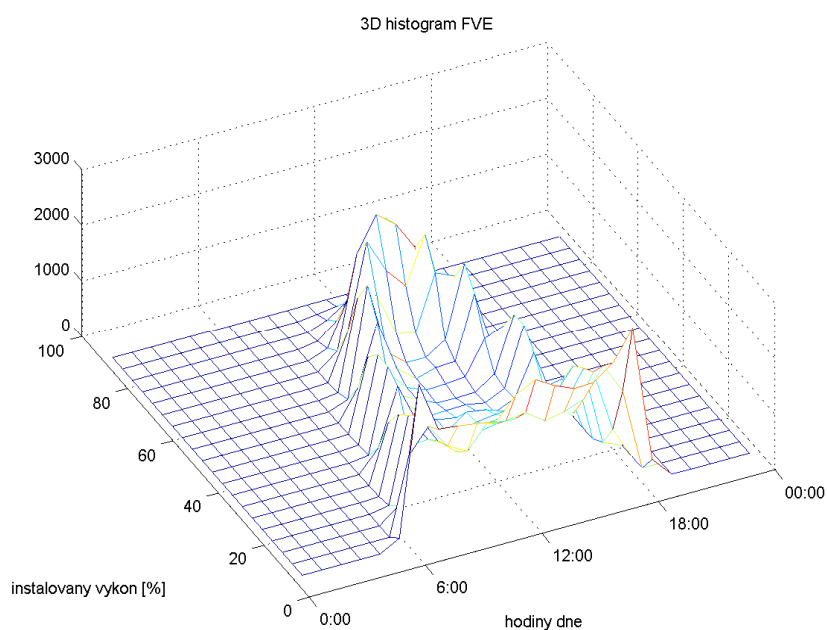
## 4.1. Získání denních diagramů

Cílem této kapitoly je získání denních diagramů (dále budeme značit DD) pro každé období a třídu oblačnosti, problém je však nedostatek dat pro takové dělení – při čtyřech obdobích a šesti třídách bychom potřebovali velké množství dat pro všech dvacet čtyři skupin. Některé skupiny jsou pro určité období spíše výjimečné, proto musíme zvolit jiný postup. Vytvoříme DD pro celý rok a všechny třídy oblačnosti společně  $DD(rok)$ , poté DD pro jednotlivá období neohledně na počasí  $DD(období)$  a DD pro jednotlivé třídy oblačnosti bez ohledu na období  $DD(třída\ oblačnosti)$ . Poté budeme získávat požadované DD pro určité období a třídu oblačnosti  $DD(třída\ oblačnosti, období)$  pomocí Bayesova vztahu, viz dále.

## 4.2. Denní diagram pro celý rok a všechny třídy oblačnosti

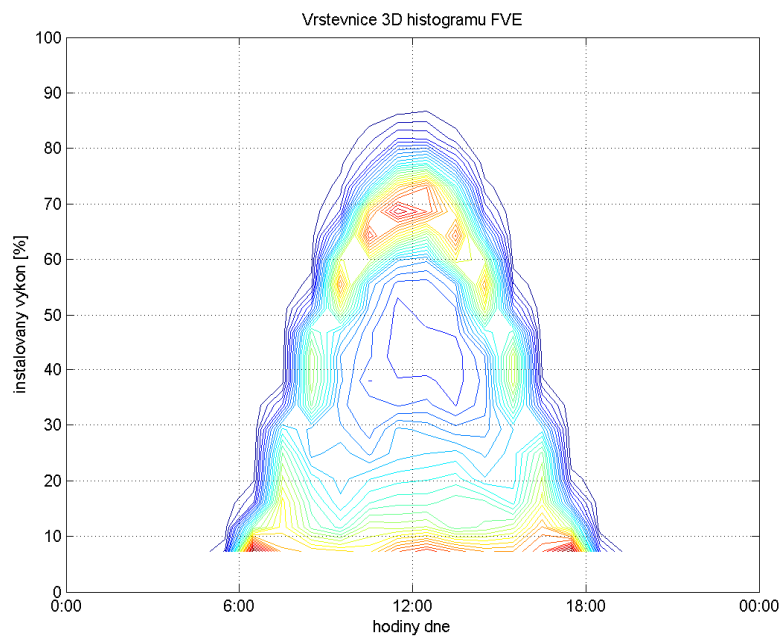
Zde si ukážeme výsledný DD pro celý rok získaný z dat z ČVUT za období 1.4.2011 až 17.3.2012, pro informaci zde uvedeme histogram výroby elektrické energie z FVE za celý rok. V tomto i v následujících grafech stejného typu jsou hodnoty, kdy vyrobená elektrická energie nižší než 10% maximální dosažitelného výkonu odstraněny. A to kvůli lepší přehlednosti.

Obr. 4.3 Histogram výroby pro celý rok



Z grafu (4.3) je vidět, že téměř všechny hodnoty jsou uvnitř oblasti ohraničené nejčastěji zastoupenými hodnotami, proto se zdá být modus vhodnou funkcí pro získání DD. Touto hypotézou se budeme zabývat dále. Z tohoto grafu není moc vidět samotné hodnoty, ty jsou dobře vidět z následujícího grafu.

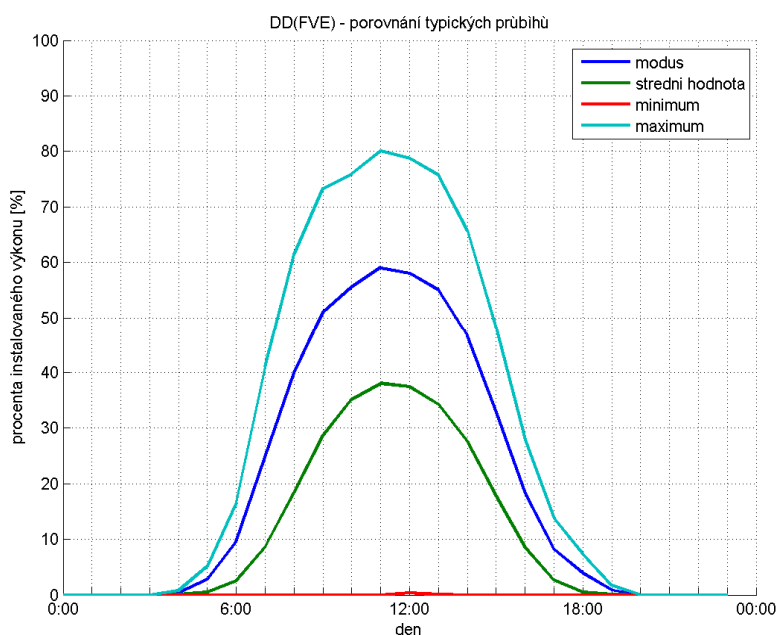
*Obr. 4.4 Vrstevnic výroby pro celý rok*



Zde jsou dobře vidět dosažené hodnoty výkonu za celý rok.

Nyní se budeme zabývat vhodnou metodou pro určení denních diagramů, při tom budeme vycházet především právě z tohoto grafu (4.4).

Obr. 4.5 Porovnání přístupů vytvoření DD



Porovnáním grafů (4.3), (4.4) a (4.5) se zdá být modus nevhodnější funkcí za všech použitých, takže ji použijeme a vytvoříme typický průběh, který dále nahradíme polynomem a ten nazveme DD. Teprve poté spočteme směrodatné odchylky od DD.

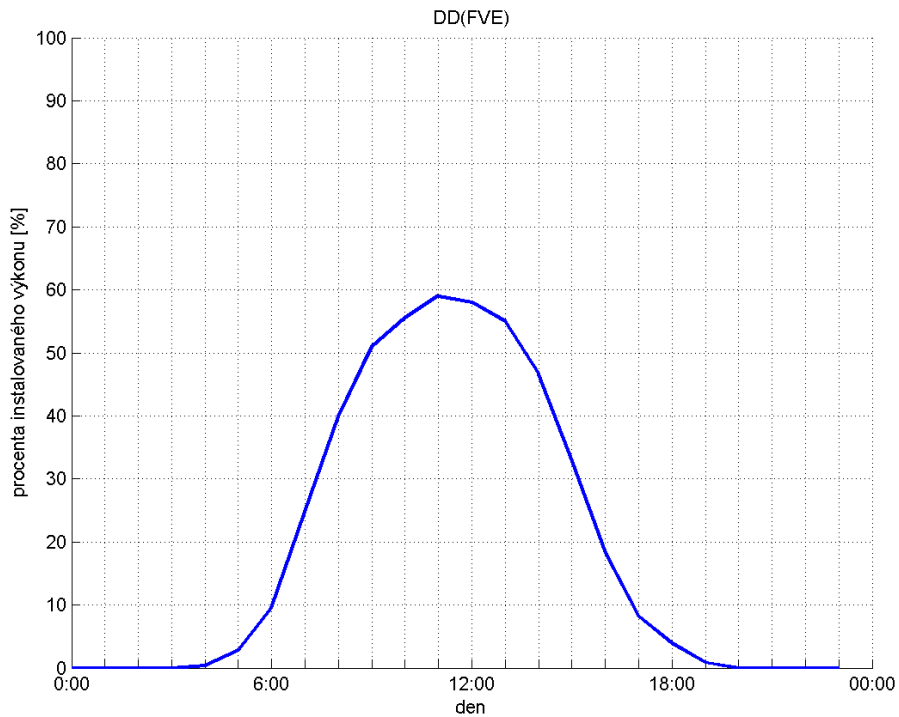
Pro vyhlazení jsme zvolili polynom stupně čtyři, ten má tvar:

$$0,0229t^4 - 1,0333t^3 + 15,1504t^2 - 78,5364t + 131,6522 \quad (4.1)$$

Zde je dobré upozornit, že za čas  $t$  dosazujeme pouze relevantní časy (např. 6 – 20 hod, které odpovídají grafu Obr. 4.1), všechny ostatní hodnoty jsou nulové.

Nyní uveďme výsledný vyhlazený denní diagram a grafy odchylek od něj.


Obr. 4.6 vyhlazený DD




Jak je vidět, tak výsledný DD získaný vyhlazením polynomem (Obr. 4.6), se od původního (Obr. 4.5) vlastně neliší. Teprve nyní můžeme spočítat směrodatné odchylky od tohoto denního diagramu DD.

Pro další účely budeme rozlišovat směrodatnou odchylku kladnou a zápornou. Kladná směrodatná odchylka  $\sigma_{DD}^+$  byla stanovena z dat, jejichž hodnota je vyšší než hodnota DD. A naopak záporná směrodatná odchylka je stanovena z dat, jejichž hodnota je nižší než DD.

Obr. 4.7 Kladná směrodatná odchylka



Obr. 4.8 Záporná směrodatná odchylka



Z předchozích grafů (4.7) a (4.8) je porovnáním s grafem (4.6) vidět, že čím je větší výkon, tím jsou větší směrodatné odchylky. Dále je patrné, že záporná směrodatná odchylka je výrazně větší, než kladná pro celý den, což je způsobeno volbou modální hodnoty jako DD.

### 4.2.1. Denní diagramy pro jednotlivé třídy oblačnosti

Zde spočteme DD pro celý rok, ale jen pro určitou třídu oblačnosti. Histogramy ze kterých zde budeme vycházet, jsou v příloze č. 1.

Postupujeme stejně jako v předchozí kapitole, výsledné DD, pak vypadají takto, viz Obr 4.9 až Obr 4.11. Polynomy popisující DD jsou uvedeny v tabulce:

Tab. 4.1 Hodnoty polynomů popisující DD pro jednotlivé třídy oblačnosti

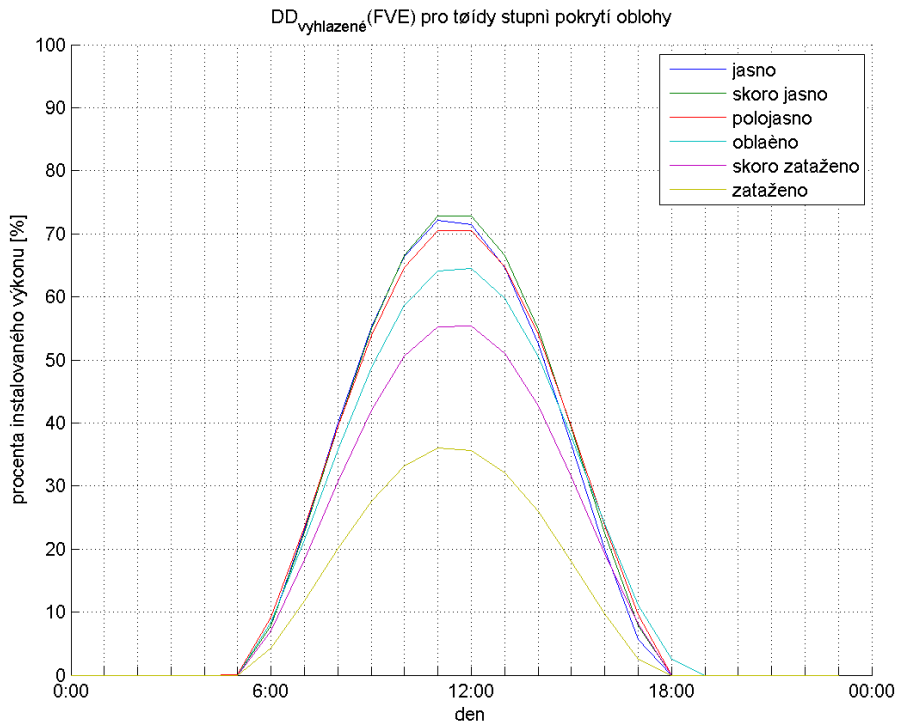
	$p_4$	$p_3$	$p_2$	$p_1$	$p_0$
<b>jasno</b>	0,0344	-1,5694	23,6034	- 130,3098	234,3457
<b>skoro jasno</b>	0,0342	-1,5746	23,9415	- 134,2781	247,3903
<b>polojasno</b>	0,0304	-1,3967	21,1231	- 116,4391	209,7377
<b>oblačno</b>	0,0260	-1,1994	18,1248	-98,9573	175,0192
<b>skoro zataženo</b>	0,0236	-1,0883	16,4981	-91,1651	164,6076
<b>zataženo</b>	0,0173	-0,7883	11,8703	-65,7921	119,5236

kde

$$p_4 t^4 + p_3 t^3 + p_2 t^2 + p_1 t + p_0 \quad (4.2)$$

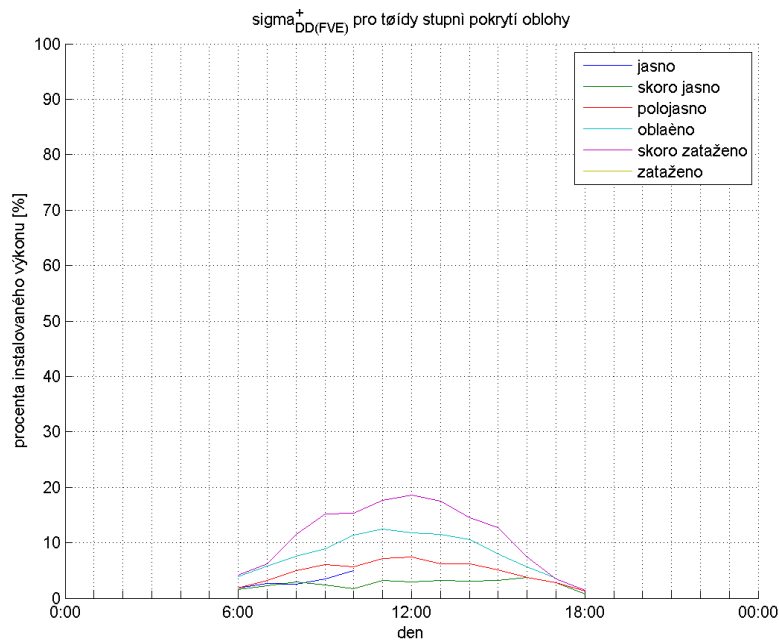


Obr. 4.9 denní diagramy pro třídy oblačnosti




Na grafu (4.9) je zajímavá velká podobnost tříd „jasno“, „polojasno“ a „skoro jasno“, nyní porovnáme směrodatné odchylky.

Obr. 4.10 Kladná směrodatná odchylka



Obr. 4.11 Záporná směrodatná odchylka



Z předchozích grafů (4.10) a (4.11) je patrné, že se přeci jen třídy „jasno“, „polojasno“ a „skoro jasno“ liší. V opačném případě by bylo výhodné třídy sloučit.

#### 4.2.2. Denní diagramy pro jednotlivá období

Zde spočteme DD pro všechny třídy oblačnosti, ale jen pro určité období. Histogramy ze kterých zde budeme vycházet, jsou v příloze č. 2.


Tab. 4.2 Hodnoty polynomů popisující DD pro jednotlivá období

	$p_4$	$p_3$	$p_2$	$p_1$	$p_0$
<b>jaro</b>	0,0265	-1,2056	17,9308	-95,7484	166,3031
<b>léto</b>	0,0237	-1,0909	16,3583	-87,3937	152,2660
<b>podzim</b>	0,0284	-1,3032	19,7055	-108,9440	196,6167
<b>zima</b>	0,0340	-1,5834	24,9054	-150,4482	300,0203

kde


$$p_4 t^4 + p_3 t^3 + p_2 t^2 + p_1 t + p_0 \quad (4.3)$$

Obr. 4.12 DD pro jednotlivá období




Stejně jako v předchozí kapitole, i zde dochází k zajímavé podobnosti více období, zde dokonce hned tří ze čtyř období. Opět potřebujeme směrodatné odchytky, aby bylo možné posoudit, zda by bylo možné nějaké třídy sloučit.

Obr. 4.13 Kladná směrodatná odchytky



Obr. 4.14 Záporná směrodatná odchylka



Vzhledem k rozdílům ve směrodatných odchylkách nemůžeme sloučit období „léto“ s žádným jiným obdobím, ale období „jaro“ a „podzim“ by bylo možné sloučit, my však zachováme všechny čtyři období.

#### 4.2.3. Výpočet denních diagramů pro období a třídy oblačnosti

Jak jsme uvedli na začátku, cílem této kapitoly je získání denních diagramů pro každé období a třídu oblačnosti, při čtyřech obdobích a šesti třídách bychom potřebovali velké množství dat pro všech dvacet čtyři skupin. Některé skupiny jsou pro určité období spíše výjimečné, proto musíme zvolit jiný postup. Poté, kdy budeme mít k dispozici větší množství dat, nedostatek je především v malém množství meteorologických dat.

Předpokládáme, že v každém období bude rozložení DD pro třídy stejné, tj. stejné budou i v rámci celého roku. Nejdříve určíme koeficienty  $k$  pro jednotlivá období jako poměr DD pro dané období a DD pro celý rok:

$$k(\text{období}) = \frac{DD(\text{období})}{DD(\text{rok})} \quad (4.4)$$

nyní určíme  $DD(\text{třída oblačnosti, období})$ :

$$DD(\text{třída oblačnosti, období}) = DD(\text{třída oblačnosti}) \cdot k(\text{období}) \quad (4.5)$$

Tímto spočteme všech dvacet čtyři DD i přes nedostatek dat.

*Tab 4.4 koeficienty pro navýšení DD období jednotlivých tříd*

	<b>jasno</b>	<b>skoro jasno</b>	<b>polojasno</b>	<b>oblačno</b>	<b>skoro zataženo</b>	<b>zataženo</b>
koeficient	1,186	1,210	1,177	1,080	0,926	0,590

Výsledné grafy jsou pro velký počet grafů v příloze č. 3. Je zajímavé, že pro třídu oblačnosti „jasno“ je výsledná střední hodnota (denní diagram) nižší, než pro třídu „skoro jasno“, ale vzhledem k tomu, že má třída „skoro jasno“ větší zápornou směrodatnou odchylku (viz Obr. 4.11) a menší kladnou směrodatnou odchylku (viz. Obr. 4.12), tak je to v pořádku – při větším množství dat by byl tento jev pravděpodobně odstraněn.

## 5. Modelování výroby z FVE

Cílem této kapitoly je získání modelů pro výrobu FVE na základě DD z předchozí kapitoly. Model výroby FVE je realizován Markovským procesem, který představuje přechod z jednoho stavu (třídy oblačnosti) do druhého. Při setrvání ve stavu je signál popsán AR procesem.

### 5.1. Odstranění proměnlivé velikosti směrodatné odchylky během dne

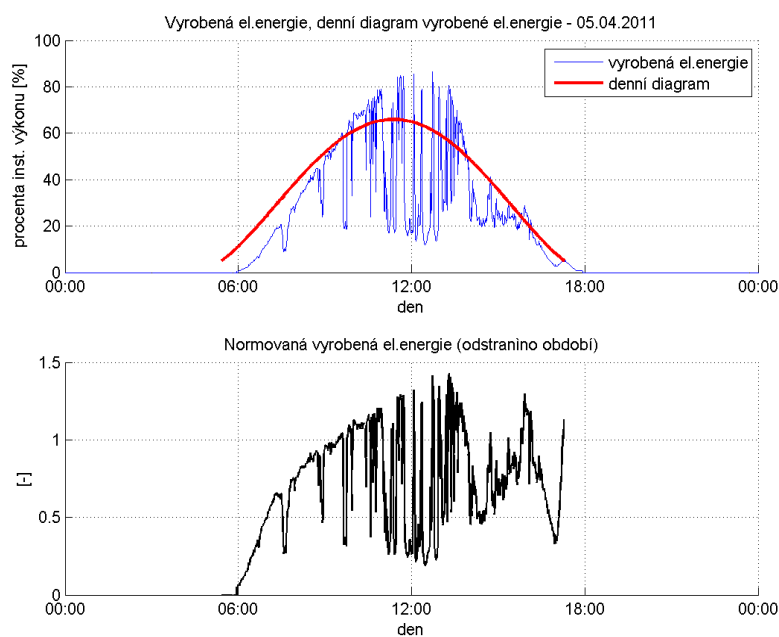
Jak jsme viděli v předchozích kapitolách, jsou hodnoty DD i  $\sigma_{DD}$  závislé na kalendářní hodině a také na ročním období, což představuje určitou komplikaci. Proto dříve než začneme zpracovávat naměřená data, tak odstraníme tyto závislosti.

Předělíme-li získaná data příslušným DD (viz Obr. 4.1), získáme normovaná data (bezrozměrná).

$$P_{FVE,normované}(t) = \frac{P_{FVE}(t)}{DD(obdobi)} \quad (5.1)$$

kde  $P_{FVE,normované}$  je výsledná hodnota vyrobené elektrické energie,  $P_{FVE}$  je naměřené hodnoty elektrické energie a  $DD(obdobi)$  z kapitoly 4.1.3.

Obr. 5.1 Normovaná dat 5. 4. 2011



Další normovaná denní měření jsou v příloze č. 4. Histogramy četností výskytu určitých hodnot normovaného výkonu jsou v příloze č. 5 – z nich je patrné, že se nejedná o normální rozložení pravděpodobnosti.

Tímto normováním odstraníme především proměnlivost směrodatné odchylky (nárůst s rostoucí střední hodnotou).

V dalších kapitolách jsou pro výpočet použity  $P_{FVE,normované}$ .

## 5.2. Modelování AR procesu

V této kapitole spočítáme parametry AR procesů, které charakterizují normovanou denní výrobu FVE z předchozí kapitoly pro jednotlivé třídy oblačnosti

Tab. 5.1 Parametry AR procesů a statistické parametry

	$a_1$	$a_2$	$a_3$	$\mu$	$\sigma^+$	$\sigma^-$
jasno	-0,5732	-0,2777	-0,1494	0,8450	0,2897	0,5455
skoro jasno	-0,7500	-0,0952	-0,1548	0,9624	0,3219	0,5447
polojasno	-0,7636	-0,0990	-0,1272	0,8490	0,4041	0,5050
oblačno	-0,7529	-0,0986	-0,1283	0,6721	0,5503	0,4379
skoro zataženo	-0,7059	-0,1683	-0,1034	0,3850	0,5513	0,2804
zataženo	-0,8333	-0,0943	-0,0619	0,1222	0,3206	0,0969

Kde AR proces je definován (viz vztah 3.16)

$$A(q^{-1})y(t) = e(t) \quad (4.2)$$

kde

$$A(q^{-1}) = 1 + a_1q^{-1} + a_2q^{-2} + a_3q^{-3} \quad (4.3)$$

## 5.3. Modelování Markovova modelu přechodů mezi jednotlivými třídami

V této kapitole spočítáme potřebné informace pro vytvoření Markovova modelu. Jednotlivé stavy Markovova modelu odpovídají třídám, tj. stupům pokrytí oblohy. K popisu použijeme hodnoty střední doby setrvání ve stavu a pravděpodobnosti přechodů. Jako první jsou četnosti (počty výskytů) dvou po sobě jdoucích stavů a to pro celý den, dopoledne a odpoledne.



Tab. 5.2 Celkové četnosti přechodů – celý den

		P(t+1)					
		jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
P(t)	jasno	8828	38	0	0	0	0
	skoro jasno	24	30546	70	0	0	0
	polojasno	0	47	40122	89	0	0
	oblačno	0	0	76	48145	101	0
	skoro zataženo	0	0	0	101	62332	73
	zataženo	0	0	0	0	96	43570

Tab. 5.3 Četnosti přechodů za dopoledne

		P(t+1)					
		jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
P(t)	jasno	3173	18	0	0	0	0
	skoro jasno	5	10824	24	0	0	0
	polojasno	0	12	13985	40	0	0
	oblačno	0	0	25	17442	34	0
	skoro zataženo	0	0	0	28	23727	28
	zataženo	0	0	0	0	46	15442

Tab. 5.4 Četnosti přechodů za odpoledne

		P(t+1)					
		jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
P(t)	jasno	1434	6	0	0	0	0
	skoro jasno	6	7837	15	0	0	0
	polojasno	0	11	10581	21	0	0
	oblačno	0	0	17	13805	30	0
	skoro zataženo	0	0	0	28	18841	16
	zataženo	0	0	0	0	19	11736

V tabulce (5.2) je zachycen celý den, ale vzhledem k tomu, že každý den v jedenáct hodin dopoledne je vydána aktuální předpověď, která by měla být přesnější, tak je rozumné rozdělit den na dvě poloviny tabulky (5.3) a (5.4).

Střední doba setrvání ve stavu budeme generovat pomocí exponenciálního rozdělení, pak:

$$T_{\text{střední\_doba}} = \frac{1}{1-p} \quad (5.4)$$

kde  $p$  je pravděpodobnost setrvání ve stavu.

Pravděpodobnosti setrvání ve stavu jsou dány vztahem:

$$p_{ii} = \frac{c_{ij}}{\sum_j c_{ij}} \quad (5.5)$$

kde  $i, j$  jsou indexy řádků a sloupců v tabulkách 4.2 až 4.4,  $c_{ij}$  jsou hodnoty četností, kdy stav  $P_i(t)$  přejde do stavu  $P_j(t + 1)$ .

*Tab. 5.5 Střední doba setrvání ve stavu – dopoledne*

jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
177,28	374,24	269,94	296,63	424,70	336,70

*Tab. 5.6 Střední doba setrvání ve stavu – odpoledne*

jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
240,00	374,19	331,66	294,72	429,20	618,68

Zajímavostí v tabulkách (5.5) a (5.6) je výrazně vyšší doby setrvání ve stavu v třídách jasno a zataženo v odpoledních hodinách.

Dále jsou určeny pravděpodobnosti přechodů z jednoho stavu do jiného stavu. Tato pravděpodobnost je:

$$P_{ij} = \frac{c_{ij}}{\sum_{j \neq i} c_{ij}} \quad \text{pro } i \neq j \quad (5.6)$$

kde  $i, j$  jsou indexy řádků a sloupců v tabulkách (4.2) až (4.4),  $c_{ij}$  jsou hodnoty četností, kdy stav  $P_i(t)$  přejde do stavu  $P_j(t + 1)$ .

Tab. 5.7 Pravděpodobnosti přechodů za dopoledne

		P(t+1)					
		jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
P(t)	jasno		1,0000	0,0000	0,0000	0,0000	0,0000
	skoro jasno	0,1724		0,8276	0,0000	0,0000	0,0000
	polojasno	0,0000	0,2308		0,7692	0,0000	0,0000
	oblačno	0,0000	0,0000	0,4237		0,5763	0,0000
	skoro zataženo	0,0000	0,0000	0,0000	0,5000		0,5000
	zataženo	0,0000	0,0000	0,0000	0,0000	1,0000	

Tab. 5.8 Pravděpodobnosti přechodů za odpoledne

		P(t+1)					
		jasno	skoro jasno	polojasno	oblačno	skoro zataženo	zataženo
P(t)	jasno		1,0000	0,0000	0,0000	0,0000	0,0000
	skoro jasno	0,2857		0,7143	0,0000	0,0000	0,0000
	polojasno	0,0000	0,3438		0,6563	0,0000	0,0000
	oblačno	0,0000	0,0000	0,3617		0,6383	0,0000
	skoro zataženo	0,0000	0,0000	0,0000	0,6364		0,3636
	zataženo	0,0000	0,0000	0,0000	0,0000	1,0000	

Z tabulek 5.7 a 5.8 jsou je vidět, že k přechodu dochází pouze mezi sousedními stavy a že pravděpodobnosti přechodu z lepšího počasí k horšímu je více pravděpodobné.

V příloze 5 jsou vykresleny histogramy z dat pro jednotlivé třídy z kapitoly 5.2, odtud je vidět, že se nejedná o normální rozdělení, proto před simulací je potřeba provést transformaci dat. K tomu se použije distribuční funkce z histogramů a normálního rozdělení  $N(0,1)$ , kde se porovnají kvantily se stejnou hodnotou distribuční funkce.

Pokud bychom chtěli modelovat simulačně, použijeme vypočtené hodnoty z tabulek 5.5 až 5.8, po simulaci jsou signály zpět „odnormovány“ pomocí  $DD(\text{období})$ .

## 5.4. Predikce vyrobené elektrické energie z FVE

Pro predikci jsou použita souhrnná data z ČR (v procentech instalovaného výkonu), meteorologické předpovědi a  $DD(\text{třída, období})$  z kapitoly 3.1.4.

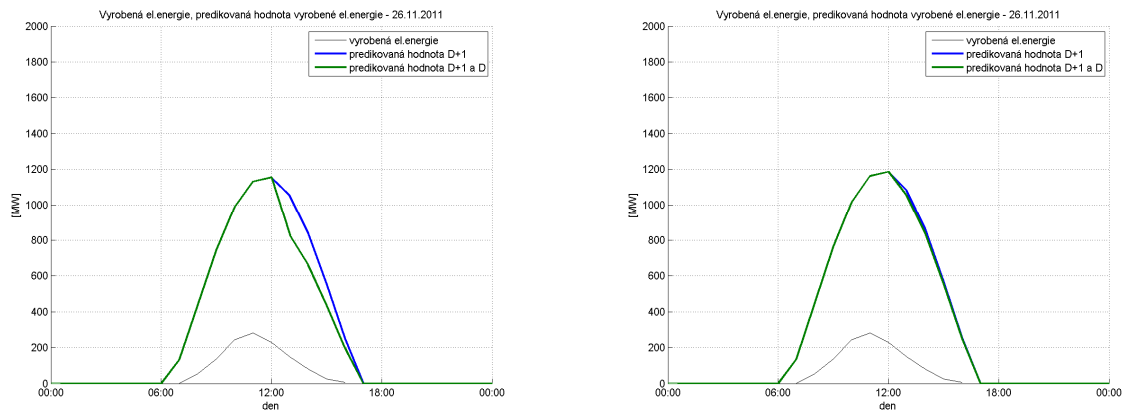
Dále se zde potýkáme ještě s jedním zásadním problémem, naměřená meteorologická data jsou pro jednotlivá místa po celé ČR, ale vyrobenou el. energii uvažujeme souhrnně za celou ČR. Je potřeba určit souhrnnou hodnotu oblačnosti (ať již z předpovědi nebo z měření) za ČR. Můžeme použít průměr oblačnosti, nebo vážený průměr – právě pomocí instalovaných výkonů FVE, viz tabulka (3.2). My zvolíme vážený průměr.

Předpovědi jsou většinou udávány jako interval, např. jasno až polojasno. V predikci proto můžeme použít buď nižší kód, který odpovídá lepšímu počasí nebo vyšší kód odpovídající horšímu počasí. Výpočet predikcí byl proveden pro obě meze předpovědi počasí.

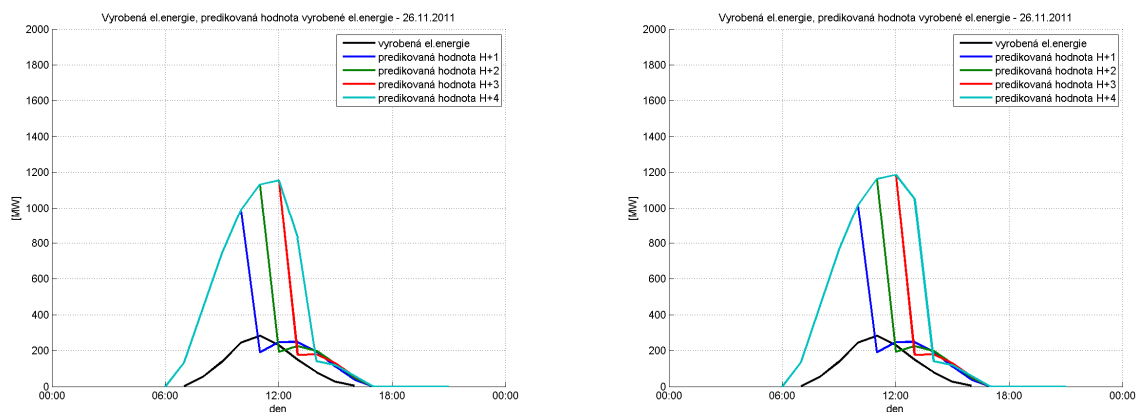
Pro obě varianty jsou vždy uvedeny tři možnosti predikce:

1. pouze na základě předpovědi z minulého dne (označeno - predikovaná hodnota D+1)
2. pro odpoledne je použita aktuální předpověď, pro dopoledne je použita předpovědi z minulého dne (označeno - predikovaná hodnota D+1 a D)
3. na základě předpovědi a aktuálního měření hodnot stanovena predikce na
  - 1 hodinu dopředu (označeno - predikovaná hodnota H+1)
  - 2 hodiny dopředu (označeno - predikovaná hodnota H+2)
  - 3 hodiny dopředu (označeno - predikovaná hodnota H+3)
  - 4 hodiny dopředu (označeno - predikovaná hodnota H+4)

Obr. 5.2 Vyrobena elektrická energie, predikce pouze na základě předpovědi z minulého dne a predikce, kdy pro odpoledne je použita aktuální předpověď



Obr. 5.3 Vyrobena elektrická energie, predikce na základě předpovědi a aktuálního měření hodnot



a) předpověď = „horší“ počasí

b) předpověď = „lepší“ počasí

## 5.5. Chyba predikce

Chyba predikce vyrobené elektrické energie je :

$$\Delta P_{FVE}(t) = P_{FVE}(t) - \widehat{P}_{FVE}(t) \quad (5.7)$$

kde  $P_{FVE}$  je vyrobená elektrická energie,  $\widehat{P}_{FVE}$  je predikce vyrobené elektrické energie.

Hodnoty  $P_{FVE}$  a  $\widehat{P}_{FVE}$  jsou v procentech instalovaného výkonu, hodnoty v MW získáme vynásobením  $\widehat{P}_{FVE}$  a instalovaným výkonem viz kapitola 2.1.

### 5.5.1. Varianta „horší“ počasí

Predikce vyrobené elektrické energie je určena pro vyšší kódy, tj. pro předpověď horšího počasí. Statistické vyhodnocení chyby predikce v procentech instalovaného výkonu pro tři varianty predikce.

*Tab. 5.9 Predikce pouze na základě předpovědi z minulého dne*

	celý den		dopoledne		odpoledne	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-6,83	16,60	-20,10	9,14	-16,87	4,66
léto	-1,32	16,05	-2,71	23,20	-11,69	13,46
podzim	-7,71	16,93	-11,14	21,15	-18,55	11,54
zima	-12,65	12,91	-15,86	14,54	-13,35	9,26
celý rok	-12,15	17,19	-9,86	20,73	-14,56	12,00

*Tab. 5.10 Predikce, kdy pro odpoledne je použita aktuální předpověď*

	celý den		dopoledne		odpoledne	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-6,30	16,34	-20,10	9,14	-15,17	5,65
léto	-1,31	15,89	-2,71	23,20	-11,63	13,10
podzim	-7,59	16,10	-11,14	21,15	-18,22	8,86
zima	-12,47	12,57	-15,86	14,54	-12,93	8,82
celý rok	-12,02	16,82	-9,86	20,73	-14,28	10,92

Tab. 5.11 Predikce na základě předpovědi a aktuálního měření hodnot - dopoledne

	na hodinu dopředu		na 2 hodiny dopředu		na 3 hodiny dopředu		na 4 hodiny dopředu	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-22,08	11,72	-20,10	9,14	-20,10	9,14	-20,10	9,14
léto	-6,46	21,25	-2,71	23,20	-2,71	23,20	-2,71	23,20
podzim	-10,49	18,15	-11,14	21,15	-11,14	21,15	-11,14	21,15
zima	-10,23	15,57	-15,86	14,54	-15,86	14,54	-15,86	14,54
celý rok	-9,13	18,61	-9,86	20,73	-9,86	20,73	-9,86	20,73

Tab. 5.12 Predikce na základě předpovědi a aktuálního měření hodnot - odpoledne

	na hodinu dopředu		na 2 hodiny dopředu		na 3 hodiny dopředu		na 4 hodiny dopředu	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-1,76	1,35	-3,14	1,48	-6,87	4,54	-13,77	9,55
léto	-5,77	4,82	-7,81	6,07	-10,68	7,80	-14,74	10,34
podzim	-8,47	5,59	-10,26	6,68	-12,46	8,12	-15,32	10,26
zima	-4,33	3,49	-4,14	3,90	-3,35	4,28	-4,05	7,16
celý rok	-6,23	5,05	-7,51	6,24	-9,06	8,01	-11,74	10,72

### 5.5.2. Varianta „lepší“ počasí

Predikce vyrobené elektrické energie je určena pro vyšší kódy, tj. pro předpověď horšího počasí. Statistické vyhodnocení chyby predikce v procentech instalovaného výkonu pro tři varianty predikce.

*Tab. 5.13 Predikce pouze na základě předpovědi z minulého dne*

	celý den		dopoledne		odpoledne	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-8,64	17,97	-23,48	10,68	-18,87	6,37
léto	-5,43	17,76	-11,92	23,93	-17,78	13,94
podzim	-12,99	20,10	-21,07	23,64	-24,52	12,35
zima	-20,70	16,89	-27,03	17,02	-20,14	11,93
celý rok	-20,33	18,60	-19,89	22,64	-20,78	13,10

*Tab. 5.14 Predikce, kdy pro odpoledne je použita aktuální předpověď*

	celý den		dopoledne		odpoledne	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-8,72	17,99	-23,48	10,68	-19,14	6,00
léto	-5,12	17,72	-11,92	23,93	-16,59	14,96
podzim	-12,82	19,60	-21,07	23,64	-23,99	11,01
zima	-20,39	16,85	-27,03	17,02	-19,39	12,10
celý rok	-19,92	18,63	-19,89	22,64	-19,96	13,19



Tab. 5.15 Predikce na základě předpovědi a aktuálního měření hodnot - dopoledne

	na hodinu dopředu		na 2 hodiny dopředu		na 3 hodiny dopředu		na 4 hodiny dopředu	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-24,22	11,30	-23,48	10,68	-23,48	10,68	-23,48	10,68
léto	-12,27	20,32	-11,92	23,93	-11,92	23,93	-11,92	23,93
podzim	-16,71	19,96	-21,07	23,64	-21,07	23,64	-21,07	23,64
zima	-17,95	19,87	-27,03	17,02	-27,03	17,02	-27,03	17,02
celý rok	-15,66	20,17	-19,89	22,64	-19,89	22,64	-19,89	22,64

Tab. 5.16 Predikce na základě předpovědi a aktuálního měření hodnot - odpoledne

	na hodinu dopředu		na 2 hodiny dopředu		na 3 hodiny dopředu		na 4 hodiny dopředu	
	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]	$\mu$ [%]	$\sigma$ [%]
jaro	-1,76	1,35	-3,14	1,48	-6,87	4,54	-13,77	9,55
léto	-5,77	4,82	-7,81	6,07	-10,68	7,80	-14,74	10,34
podzim	-8,47	5,59	-10,26	6,68	-12,46	8,12	-15,32	10,26
zima	-4,33	3,49	-4,14	3,90	-3,35	4,28	-4,99	9,38
celý rok	-6,23	5,05	-7,51	6,24	-9,06	8,01	-12,02	11,03

Porovnáním příslušných hodnot zjistíme, že varianta s horším počasím má menší směrodatnou odchylku a především výrazně menší střední hodnotu chyby predikce pro dopoledne. Odpolední hodnoty se shodují.

Porovnáním hodnot v tabulkách 5.9 až 5.12, resp. 5.13 až 5.16 zjistíme, že nejpřesnější je dle očekávání varianta, kdy se do predikce uvažují i aktuální hodnoty měření. Naopak nejméně úspěšná je varianta, kdy predikujeme na celý den na základě předpovědi z minulého dne.

### 5.5.3. Citlivost chyby predikce na velikost instalovaného výkonu

Zde si prověříme, jaký vliv na přesnost predikce má množství instalovaného výkonu, k tomu nám poslouží střední hodnota chyby a směrodatná odchylka. Bereme v úvahu variantu „horší“ počasí.

Tab. 5.17 Vliv množství instalovaného výkonu na chybu predikce

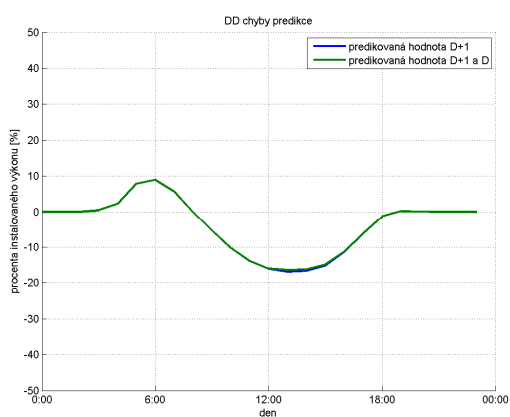
instalovaný výkon	chyba predikce FVE pro celý den = predikovaná hodnota D-1		chyba predikce FVE pro celý den = predikovaná hodnota D-1 a D	
	$\mu$ [MW]	$\sigma$ [MW]	$\mu$ [MW]	$\sigma$ [MW]
0[MW]				
dopoledne	0,00	0,00	0,00	0,00
odpoledne	0,00	0,00	0,00	0,00
500[MW]				
dopoledne	-49,29	103,67	-49,29	103,67
odpoledne	-72,78	60,00	-71,40	54,61
1000[MW]				
dopoledne	-98,57	207,34	-98,57	207,34
odpoledne	-145,56	119,99	-142,79	109,23
1500[MW]				
dopoledne	-147,86	311,02	-147,86	311,02
odpoledne	-218,34	179,99	-214,19	163,84
2000[MW]				
dopoledne	-197,14	414,69	-197,14	414,69
odpoledne	-291,12	239,98	-285,58	218,46

Z tabulky je patrné, že větší množství instalovaného výkonu vede, dle očekávání, ke změně – roste střední hodnota i směrodatná odchylka chyby predikce, i když uvedené změny jsou pravidelné.

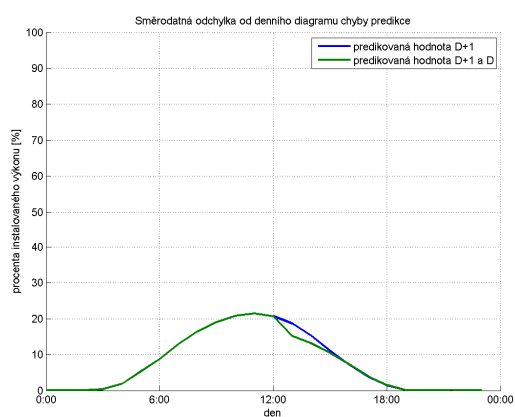
## 5.5.4. Denní diagramy chyby predikce

V předchozí kapitole jsou výsledky statistických parametrů chyby predikce pro celé časové úseky. Tady jsou statistické parametry chyby predikce pro každou hodinu kalendářního dne. Dá se očekávat, že i tyto parametry budou v čase proměnné. Denní diagram je počítán jako střední hodnota.

Obr. 5.4 Chyba predikce, kdy predikce je pouze na základě předpovědi z minulého dne a predikce, kdy pro odpoledne je použita aktuální předpověď (předpověď = „horší“ počasí)




a) střední hodnota

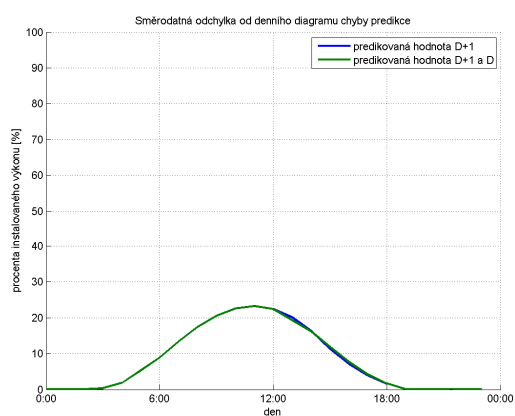


b) směrodatná odchylka

Obr. 5.5 Chyba predikce, kdy predikce je pouze na základě předpovědi z minulého dne a predikce, kdy pro odpoledne je použita aktuální předpověď (předpověď = „lepší“ počasí)




a) střední hodnota




b) směrodatná odchylka

Obr. 5.6 Chyba predikce, kdy predikce na základě předpovědi a aktuálního měření hodnot (předpověď = „horší“ počasí)




a) střední hodnota




b) směrodatná odchylka

Obr. 5.7 Chyba predikce, kdy predikce na základě předpovědi a aktuálního měření hodnot (předpověď = „lepší“ počasí)



a) střední hodnota



b) směrodatná odchylka

## 5.6. Vliv chyby predikce na regulační odchylku ACEo

Naším cílem je minimalizovat chybu predikce. Právě chyba predikce se projeví v signálu regulační odchylky v otevřené smyčce nenarušeného provozu ACEo. Z dat ACEo pro roky 2010 a 2011 určíme statistiky:  $\mu_{ACEo}(2010)$ ,  $\sigma_{ACEo}(2010)$ ,  $\mu_{ACEo}(2011)$  a  $\sigma_{ACEo}(2011)$

Statistické parametry chyby predikce se projeví v signálu regulační odchylky ACE, což vlastně je odchylka salda (to lze chápat jako rozdíl výroby a spotřeby). Tento signál popisuje chování soustavy ČR. Je to signál, který vznikne po zásahu regulací ČEPSu (reguluje se běžné kolísání přenosové soustavy a také výpadky). Pokud chceme zkoumat vliv jen určitého jevu, například vliv FVE, pak je zapotřebí používat ACEo, to je signál bez regulací a také bez okamžiků, kdy nastal výpadek některého z velkých bloků. Neuvažujeme výpadky všech bloků, ale jen těch, které mají instalovaný výkon vyšší než 200MW.

Výroba na FVE až do roku 2011 nebyla tolik zastoupena, proto můžeme předpokládat, že pro rok 2010 byly odchylka ACEo a výroba FVE (tedy i chyba predikce FVE) nezávislé. Od roku 2011 to však již neplatí, protože v roce 2011 došlo k masivnímu nárůstu výroby FVE a tudíž je již zastoupena i v ACEo. Proto jsou směrodatné odchylky sečteny geometricky:

$$\sigma_{ACEo}(2011) = \sqrt{\sigma_{ACEo}(2010)^2 + \sigma_{chyba\ predikce}^2}$$

Z toho vyplývá, že statistika chyby predikce signalizuje, o kolik bude zapotřebí více regulačních záloh.

Skutečný rozdíl mezi  $\sigma_{ACEo}(2010)$  a  $\sigma_{ACEo}(2011)$  je ale menší než nám vychází. Navíc se dopouštíme systematické chyby predikce v průběhu dne, resp. **DDchyby predikce** není nulový, to je v případné další práci nutné nejprve odstranit.

Tab. 5.18 Porovnání statistických parametrů pro „horší“ počasí

	data ACEo 2011		data ACEo 2010		chyba predikce FVE na 1 hodinu dopředu		data ACEo 2010 + FVE	
	$\mu$ [MW]	$\sigma$ [MW]	$\mu$ [MW]	$\sigma$ [MW]	$\mu$ [MW]	$\sigma$ [MW]	$\mu$ [MW]	$\sigma$ [MW]
dopoledne	-3,62	149,18	12,00	133,24	-180,02	367,33	-168,01	390,75
odpoledne	19,54	121,98	13,19	114,64	-122,91	99,68	-109,73	151,92

Výsledky potvrzují, že je v prediktorech systematická chyba. Statistické parametry neodpovídají, výsledkům predikce, kterou používají společnosti E.ON a ČEZ.

## 5.7. Výše regulačních záloh

Statistické parametry jsou dále použity pro stanovení výše regulačních záloh tzv. PpS, konkrétně terciální regulaci. Obecně řečeno jsou výše potřeb dány:

$$RZ = q_E \cdot \sigma_{ACE_0}$$

kde  $q_E$  je hodnota oboustranného kvantilu odpovídající pravděpodobnosti 2,206%, která je dána standardem spolehlivosti z Kodexu přenosové soustavy.

Odtud plyne navýšení regulačních záloh vlivem nově instalovaných fotovoltaických elektráren.

## 6. Možná vylepšení

V bodě 5.1 je možné nejprve odečíst samotný DD, teprve poté odstranit proměnlivost směrodatné odchylky během dne normováním

$$P_{FVE,normované}(t) = \frac{P_{FVE}(t) - DD(\text{období})}{DD(\text{období})} \quad (6.1)$$

tím se místo poměru výkonu dostane k poměrné odchylce od předpokládaného DD.

V bodě 5.6 jsme narazili na problém systematické chyby predikce. To je zapotřebí odstranit například zvýšením přesnosti DD (např. rozdělení do více období, jiná volba rozdělení...)

Předpověď počasí je samostatná pro každý kraj, proto i predikci můžeme určovat pro každý kraj samostatně v normovaných hodnotách v procentech instalovaného výkonu (dle tabulky 3.2). Potom hodnoty pro jednotlivé kraje přepočítáme na MW a tím bude predikce pro celou ČR součtem těchto predikcí.

## 7. Závěr

Cílem této práce bylo navrhnout prediktor výroby elektrické energie z fotovoltaických elektráren (FVE) za účelem snížení nárůstu podpůrných služeb (PpS) provozovatele přenosové sítě v důsledku nedávného nárůstu počtu FVE.

Nejdříve jsme na základě analýzy zvolili metodu upřesnění dlouhodobého trendu pomocí AR procesu. Pro určení dlouhodobých trendů jsme rozdělili rok na čtyři období a pro každé z nich zavedli šest tříd počasí. Získali jsme tedy dvacet čtyři trendů, čím větší počet tříd, tím lze zvolit vhodnější trend, ale výrazně roste nutnost velkého množství dat, už pro tuto variantu byl problém s daty pro některé třídy.

Dále jsme se zde snažili vyjádřit vliv FVE na množství PpS, resp. jejich nárůst. To je vlastně nejdůležitější předpoklad pro snížení potřebného množství PpS predikcí výroby FVE.

Byla zde zmíněna důležitá fakta a nastíněno několik možností pro realizaci tohoto prediktoru a ověřili jsme je na reálných datech. Abychom je mohli porovnat a zvolit tu nejvhodnější možnost by však bylo zapotřebí mnohem více dat z více zdrojů.





## 8. Použité zdroje


- [1] <http://cs.wikipedia.org/wiki/Oblačnost>
- [2] <http://cs.wikipedia.org/wiki/Osvětlivost>
- [3] <http://www.zkratky.cz/Wp/16927>
- [4] [http://cs.wikipedia.org/wiki/Fotovoltaický\\_článek](http://cs.wikipedia.org/wiki/Fotovoltaický_článek)
- [5] Kolektiv autorů Centra aplikované kybernetiky při ČVUT:  
Metodika SESyS 2008
- [6] Janeček, E., Fialová, A.: Metodika SESyS 2009
- [7] Janeček, E., Fialová, A., Janeček, P., Houdová, L.: Zahrnutí FVE  
do modelu SESyS
- [8] Reif, J., Kobeda, Z.: Úvod do pravděpodobnosti a spolehlivosti.  
Západočeská univerzita v Plzni, 2003
- [9] Šimandl, M.: Identifikace systémů a filtrace. Západočeská  
univerzita v Plzni, 2001
- [10] Šimandl, M.: Adaptivní řízení a zpracování signálů. Západočeská  
univerzita v Plzni, 2003

## 9. Příloha


### 9.1. Denní diagramy pro jednotlivé třídy oblačnosti




3D histogram FVE  
třída stupni pokrytí oblohy - skoro jasno




Vrstevnice 3D histogramu FVE  
třída stupni pokrytí oblohy - skoro jasno




3D histogram FVE  
třída stupni pokrytí oblohy - polojasno




Vrstevnice 3D histogramu FVE  
třída stupni pokrytí oblohy - polojasno




3D histogram FVE  
třída stupni pokrytí oblohy - oblačno




Vrstevnice 3D histogramu FVE  
třída stupni pokrytí oblohy - oblačno




3D histogram FVE  
třída stupni pokrytí oblohy - skoro zataženo




Vrstevnice 3D histogramu FVE  
třída stupni pokrytí oblohy - skoro zataženo



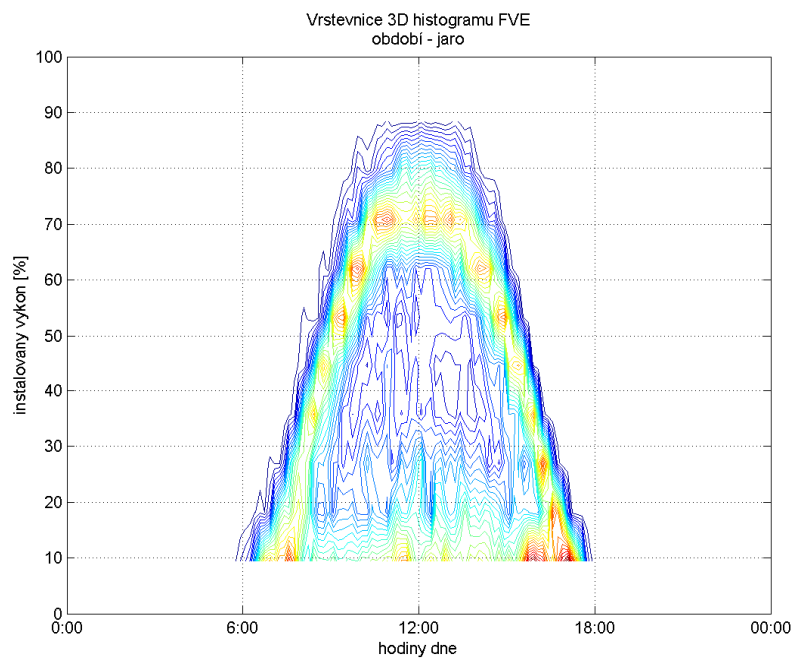

3D histogram FVE  
třída stupni pokrytí oblohy - zataženo



Vrstevnice 3D histogramu FVE  
třída stupni pokrytí oblohy - zataženo




## 9.2. denní diagramy pro jednotlivá období







3D histogram FVE  
období - leto




Vrstevnice 3D histogramu FVE  
období - leto




3D histogram FVE  
období - podzim




Vrstevnice 3D histogramu FVE  
období - podzim





3D histogram FVE  
období - zima







Vrstevnice 3D histogramu FVE  
období - zima







### 9.3. vyhlazené DD pro jednotlivá období a třídy oblačnosti



















## 9.4. Normované denní měření





## 9.5. Histogramy četností výskytu určitých hodnot pro normované výkony a pro jednotlivé třídy oblačnosti

