

Univerzita Karlova v Praze
Matematicko-fyzikální fakulta

BAKALÁŘSKÁ PRÁCE



Patrik Benáček

Využití meteorologických pozorování v objektivní analýze atmosféry

Meteorologie a klimatologie

Vedoucí bakalářské práce: RNDr. Radmila Brožková, CSc.,

Studijní program: obecná fyzika
meteorologie a klimatologie

2008

Na tomto místě bych chtěl především poděkovat vedoucí bakalářské práce RNDr. Radmile Brožkové, CSc. a konzultantům Mgr. Aleně Trojákové a Mgr. Martině Lacinové za vzácné rady a připomínky při vypracování této práce.

Prohlašuji, že jsem svou bakalářskou práci napsal samostatně a výhradně s použitím citovaných pramenů. Souhlasím se zapůjčováním práce a jejím zveřejňováním.

V Praze dne 27.5.2008

Patrik Benáček

Obsah

Úvod	v
1 Objektivní analýza	1
1.1 Úvod do numerické předpovědi počasí	1
1.1.1 Analýza naměřených dat	3
1.1.2 Předběžný odhad a asimilace dat	4
1.1.3 Asimilační modely	4
1.2 Metody objektivní analýzy	6
1.2.1 Teorie optimálního odhadu v meteorologii	6
1.2.2 Modelování matice chyb měření	10
1.2.3 Modelování matice chyb předběžného odhadu	10
1.2.4 Optimální interpolace (OI)	12
1.2.5 Tří-dimenzionální variační analýza (3D-Var)	13
1.2.6 Čtyř-dimenzionální variační analýza (4D-Var)	14
1.2.7 Nudging	15
2 Meteorologická pozorování	17
2.1 Základní typy meteorologických pozorování	18
2.1.1 Družicová pozorování	20
3 Využití meteorologických pozorování pro asimilaci dat	30
4 Závěr	40
Literatura	41

Název práce: Využití meteorologických pozorování v objektivní analýze atmosféry

Autor: Patrik Benáček

Katedra (ústav): Meteorologie a klimatologie

Vedoucí bakalářské práce: RNDr. Radmila Brožková, CSc.

e-mail vedoucího: Radmila.Brozkova@chmi.cz

Abstrakt: Asimilace dat má velký význam pro analýzu atmosféry, která je základní počáteční podmínkou pro početní předpověď počasí. Po úvodu této práce definujeme pojmy analýza a asimilace dat, popíšeme současné metody objektivní analýzy, odvozené z teorie optimálního odhadu v meteorologii, jejich základní výpočetní rovnice, vlastnosti a využití v asimilaci dat. Další kapitola je věnována typům pozorování, měřeným meteorologickým veličinám a zaměříme se zde především na družicová pozorování, která jsou v poslední době pro asimilaci modelových dat nejdůležitější. Poslední částí práce je seznámení se s kontrolou kvality dat, statistické shrnutí využití měření a názorná ukázka na obrázcích z Evropského centra pro střednědobou předpověď ECMWF.

Klíčová slova: Analýza, asimilace dat, metody objektivní analýzy, typy pozorování, využití pozorování v asimilaci dat.

Title: Use of meteorological observations in objective analysis of the atmosphere

Author: Patrik Benáček

Department: Meteorology and climatology

Supervisor: RNDr. Radmila Brožková, CSc.

Supervisor's e-mail address: Radmila.Brozkova@chmi.cz

Abstract: Assimilation of observation have a significance for analysis of atmosphere, creating a initial condition for numerical weather prediction. After the introduction we recall a notion of analysis and asimilation, we discuss present methods of objective analysis, which are derived from theory of optimal estimation in meteorology, their basic equations, properties and use in data assimilation. The next chapter is devoted to observation types, measured meteorological parameters and we focused on satellite observation, which are the most important for data assimilation of late years. In the last part of my thesis we introduce quality control of observation, statistical use of observations in data assimilation and we demonstrate it on figures of ECMWF.

Keywords: Analysis, data assimilation, objective methods of analysis, observation types, use of observations in data assimilation.

Úvod

Předpověď počasí se stala zásadní znalostí v mnoha směrech pro vysoce průmyslové země. Každodenní předpověď a včasná varování před nebezpečnými meteorologickými jevy, vydávané národními meteorologickými organizacemi pro širokou veřejnost a průmyslové obchody, má především obrovský ekonomický význam.

V současné době se pro předpověď počasí využívá numerických předpovědních modelů, které jsou nyní na takovém stupni, že přesnost předpovědi závisí především na počátečních podmínkách, tedy na naměřených klíčových meteorologických parametrech, kterými jsou vertikální profily větru, teploty, vlhkosti, tlaku a dalšími informacemi jako je množství srážek, pokrytí oblohy nebo měření vyzařování a sněhové a ledové pokrývky.

Hustota těchto poskytnutých informací o stavu atmosféry, není po celé Zemi stejná. Je pochopitelné, že nejvíce měření získáváme z pevniny, kde probíhají stálá výšková i pozemní měření. Měření z oblasti oceánů se dlouho spoléhala pouze na lodě a bóje, ovšem v 60. letech 20. století nastupují družicová pozorování, která poskytují velkoplošná měření a stávají se tak mocnou zbraní pro asimilační modely a výslednou budoucí předpověď. Společně s rozvojem meteorologických přístrojů je právě v numerické předpovědi obrovský potenciál na zlepšení a zpřesnění předpovědi počasí.

V práci se seznámíme s metodami objektivní analýzy, které nám připravují, z dostupných měření a minulých předpovědí, pole počátečních podmínek, zásadních pro výpočet budoucí předpovědi počasí. Dále se seznámíme s typy pozorování, které nám numerické modely pomocí měřených dat aktualizují a vytváří tak co nejlepší odhad analýzy, ze které je následně počítána předpověď. Zásadním krokem před samotnou asimilací naměřených dat je kontrola jejich kvality. Kontrola kvality je proces, který nám nevhodná či nepřesná data vyřadí a určuje tak jejich využití pro asimilaci. Tímto tématem se zabýváme v poslední kapitole.

Kapitola 1

Objektivní analýza

1.1 Úvod do numerické předpovědi počasí

Hlavním důvodem studia cirkulace atmosféry je odjakživa požadavek lepší předpovědi počasí. Dostupná a spolehlivá meteorologická data, a jejich předpověď, hrají důležitou úlohu v řadě odvětví lidské činnosti zahrnující energetiku, dopravu, zemědělství, obchod, sport, kulturu, životní prostředí apod. Počasí se stává nejen důležitým faktorem v lidském životě, ale správná a včasná předpověď nebezpečných jevů (jako bouřky, povodně vichřice. . .) pomůže včas se připravit a zachránit tak mnoho lidských životů. Právě toto je klíčový faktor a hnací motor, aby se kladl velký důraz na předpověď počasí.

Počátky meteorologických pozorování sahají velmi hluboko do minulosti. První meteorologické přístroje, a pravidelná meteorologická měření, se objevily až v polovině 18. století. Další jedno století čekalo lidstvo na vznik synoptických map a zrod subjektivní analýzy, která byla v dobách Richardsona (1922) nahrazena analýzou objektivní. Už zpočátku se věřilo, že objektivní analýza v sobě skrývá obrovský potenciál na zpřesnění budoucí předpovědi počasí a přes počáteční skepsi a konflikty se synoptickou meteorologií, stála v první polovině 20. století meteorologie u zrodu nového přesnějšího způsobu početní předpovědi, nebo-li numerické předpovědi počasí.

Pojem početní předpověď definujeme [9] jako:

Předpověď meteorologických prvků, která je výsledkem časové integrace prognostických rovnic některého fyzikálního modelu atmosféry, prováděné na samočinných počítačích metodami numerické matematiky.

Jejím jasným cílem je tedy co nejrychleji zpracovat naměřené údaje z meteorologických přístrojů a pomocí počítačové simulace vývoje atmosféry vypočítat pravděpodobný budoucí stav.

Hlavní problém současné meteorologie

Současným, a jistě i budoucím, hlavním problémem předpovědi počasí je zadání počátečních podmínek. Již Bjerknes (1911) uvádí 2 podmínky, které musí být pro úspěšnou budoucí předpověď stavu atmosféry splněny [2]:

1. Současný stav atmosféry musí být charakterizovaný tak přesně, jak je jen možné.
2. Musí být známy zákony, podle kterých se následné stavy atmosféry utváří z předchozích.

Celý proces početní předpovědi můžeme rozdělit do 3 částí, které ve své době byly navrženy Bjerknesem. Těchto 3 problémů se budeme nadále držet:

- Měření meteorologických prvků
- Diagnóza (analýza) prvků
- Předpověď prvků

Je jasné, že měření a analýza prvků souvisí s první Bjerknesovou podmínkou, kdy kvalitní naměřená data a analýza z předchozích modelových výstupů nám poskytnou velmi přesný popis současného stavu atmosféry. Nejprve se budeme zabývat pojmem *analýza* prvků, abychom si udělali obecný přehled, jak numerické modely pracují a poté se budeme zabývat jejich hlavním problémem, tj. zpřesňování počátečních hodnot využitím *měření meteorologických prvků*.

Samotná předpověď prvků a s tím spjaté zákony (jak uvádí Bjerknes v druhé podmínce) jsou již nad rámec této práce a velmi stručně se o ni zmíním v následujícím odstavci. Blíže se s předpovědí meteorologických prvků můžeme seznámit např. v [2].

Předpověď meteorologických prvků

K předpovědi meteorologických prvků užíváme rovnice, odvozené z fyzikálních zákonů platných pro atmosféru, jejichž integrací dokážeme určit budoucí stav ze současného stavu atmosféry. Rovnice tvoří nelineární systém parciálních diferenciálních rovnic, a proto je nelze řešit analyticky, ale pouze na výkonných počítačích tzv. numerickými metodami.

Výsledná analýza numerických modelů bývá využívána [11]:

- jako předpověď počasí pro informování široké veřejnosti, varovné služby, energetiku, leteckou a silniční dopravu, vodní hospodářství, zemědělství, sport...
- jako vstup do specifických modelů: srážkové odtokové modely (slouží k předpovědi povodní), modely popisující šíření daného typu znečištění (využívány při průmyslových haváriích) a jiných dalších aplikací

- k předpovědi nebezpečných extrémních jevů (studie jsou z důvodu rozlišení modelů teprve na počátku, ovšem do budoucna existuje potenciál zlepšení tohoto typu předpovědi)
- využití podniku pro rozvod energetických sítí, pro vojenské aplikace aj.

1.1.1 Analýza naměřených dat

Atmosféra je největší proměnnou zemského klimatického systému v prostoru a čase, která je uvedena do pohybu změn v důsledku rozdílu energie dopadající na Zemi v podobě slunečního záření.

Tyto změny dokážeme měřit pomocí *závislých meteorologických veličin*, které jak již plyne z označení se mohou navzájem ovlivňovat. Patří sem teplota, vlhkost, tlak, vítr, geopotenciál a jiné. Měření provádíme využitím meteorologických přístrojů, které jsou nepravidelně rozmístěny po celém glóbu a poskytují nám *naměřené hodnoty* nepravidelně v čase.

Naše modely ovšem pracují v jiné dimenzi, než je dimenze bodů měření. Proto je nutné zavést metody, které by nám z našich nepravidelných vstupních hodnot vytvořily uspořádanou množinu bodů s novou dimenzí. Proto zavádíme pojem analýza.

Současnou analýzu označujeme jako objektivní a můžeme ji definovat [2] jako:

Automatická procedura sloužící k odhadu atmosférických závislých proměnných (teplota, vlhkost, vítr...) v pravidelných 2D-3D mřížkách, užitím dat dostupných z nepravidelně rozmístěné sítě pozorování.

Tuto reprezentaci obvykle tvoří uzlové body modelové mřížky. V praxi to znamená, že se celá atmosféra rozdělí na malé kvádry, jejichž horizontální rozměr se pohybuje od několika kilometrů až do stovek kilometrů a vertikální rozměr je desítky až stovky metrů. Každý roh kvádrů představuje náš uzlový bod.

Počátky metody analýzy nalézáme v 2. polovině 19. století a především později u Bjerknese (1911), který rozvíjel grafické techniky čtení z diagnostických map. Tato analýza je označována jako subjektivní, jelikož závisela především na úsudku meteorologa. Metodami srovnávání předešlých synoptických map a interpolací hodnot byli schopni získat budoucí předpověď počasí na 1-2 dny. Subjektivní analýza dosáhla zlaté éry především za druhé světové války.

Tato technika ovšem nebyla dostačující a pokroky v období 1860-1920 velmi malé, a proto se během první světové války hledaly metody, které by analyzovaly pole atmosféry bez použití lidského zásahu. V době Richardsona (1922) se začala rozvíjet objektivní analýza, která se přes komplikované grafické metody, polynomiální přiblížení a metodu postupných korekcí, dostala k použití teorie optimálního odhadu v meteorologii [2], [14].

1.1.2 Předběžný odhad a asimilace dat

Zavedli jsme si tedy objektivní analýzu a rozšířením informace z bodů měření do pravidelné homogenní modelové mřížky, dostali počáteční hodnoty pro předpovědní modely. Pouze naměřená data ovšem nejsou pro úspěšnou předpověď postačující, a proto již Cressman poskytl návrh dvou důležitých předpokladů, které nám budoucí předpověď kvalitativně zlepší:

- kvalita měřených dat by měla být kontrolována automaticky
- vytvoření předběžného pole odhadu analýzy, které by mohlo být získáno z předchozí numerické předpovědi. Tento odhad se nazývá *předběžný odhad (background)* nebo *first guess*.

Předběžný odhad dává v numerické předpovědi prostor pro zavedení nového pojmu, kterým je asimilace dat. Asimilací nazýváme proces, při němž jsou naměřená data využita k opravě (modifikaci) modelových veličin, a tím ke vzniku nových počátečních podmínek pro další integraci modelu. Pro asimilaci je určující, jaká data a veličiny jsou do modelu asimilovány (tj. hodnoty jakých modelových veličin jsou modifikovány a jakou metodou je modifikace provedena) [13].

1.1.3 Asimilační modely

Numerické předpovědní modely, které slouží k přípravě pole předběžného odhadu v čase měření nazýváme asimilační modely. Jsou to v podstatě předpovědní modely využívající základní fyzikální rovnice a parametrizace fyzikálních procesů, které jsou aktualizovány přidáním nových měření.

Stavový vektor a datový operátor

Modelový stav je popisován stavovými vektory, což jsou sloupcové vektory, jejichž komponentami jsou závislé meteorologické veličiny, popisující stav atmosféry v uzlových bodech mřížky. Pro stavové vektory, které nám reprezentují namodelovaný stav atmosféry, vymezení pracovní prostor \mathbb{R}^n . V analýze často užíváme [1]:

\vec{x}_t – *truth state, skutečný stav* (nejlepší možný odhad namodelovaného stavu)

\vec{x}_b – *předběžný odhad* (odhad skutečného stavu atmosféry před analýzou a platný ve stejný čas)

\vec{x}_a – *analysis model state, analyzovaný stav* (výsledný hledaný stav analýzy modelu)

Další důležitou složkou pro asimilaci dat jsou naměřené hodnoty. Ty shromáždíme ve vektoru měření \vec{y} (*observation vektor*). Jelikož počet měření p je odlišný od počtu bodů modelové mříže n , liší se nám i dimenze prostoru měřených dat $\vec{y} \in \mathbb{R}^p$ od dimenze

stavového vektoru $\vec{x} \in \mathbb{R}^n$. Pro analýzu je nutné zavést operátor H , který nám vytvoří přechod z proměnných stavového vektoru do prostoru naměřených dat. Operátor H nazýváme datový operátor, a jedná se o matici dimenze $p \times n$. V praxi obvykle operátor H linearizujeme v okolí hodnot předběžného odhadu:

$$H(\mathbf{x}) - H(\mathbf{x}_b) \approx \mathbf{H}(\mathbf{x} - \mathbf{x}_b)$$

Operátor bude mít nejjednodušší tvar v případě, že body měření budou odpovídat uzlovým bodům modelové mřížky. Potom platí pro datový operátor $\mathbf{H} = \mathbf{I}$ (kde \mathbf{I} značí jednotkovou matici). Pokud se body měření nacházejí mimo uzlové body, je nutné hodnoty závislých meteorologických veličin interpolovat. Situace je ještě složitější např. pro družicová pozorování, kde pro měřené veličiny (např. radiance) je nutné kromě interpolace i vypočítat modelový ekvivalent radiance z modelových veličin. Tento funkční přechod je také součástí operátoru H .

Asimilační modely můžeme rozdělit podle způsobu asimilace měřených dat na nespojitě a spojitě.

Nespojitě asimilační modely

Nespojitá asimilace dat byla široce využívána v 80. letech a v řadě případů se používá dodnes. Na fungování nespojitých asimilačních modelů lépe pochopíme samotný proces asimilace dat. Proces rozdělíme do 3 fází [2]:

1. **Kontrola kvality** – Každých 6 hod jsou sesbírány naměřené hodnoty \mathbf{y}^o uvnitř časového intervalu ± 3 hod (asimilační okno) se středem asimilačního okna např. v čase 00 hod. Naměřené hodnoty, které vstupují do asimilačního modelu jsou již předem zkontrolovány automatickými systémy kontroly kvality.
2. **Objektivní analýza** – Z předešlé předpovědi získáme předběžný odhad asimilačního modelu \mathbf{x}^b . Užitím matematické interpolace, která je nástrojem datového operátoru H , vypočteme hodnoty předběžného odhadu v bodech měření, odečteme od naměřených hodnot a získáme přírůstek měření *observation increment* $\delta\mathbf{x}^o = \mathbf{x}^b - \mathbf{y}^o$. Provedeme-li objektivní analýzu tohoto přírůstku získáme *analysis increment* \mathbf{x}^a v každém bodě modelové sítě. Výsledná analýza \mathbf{x}^a je získána jako součet analysis increment a předběžného odhadu $\mathbf{x}^a = \mathbf{x}^b + \delta\mathbf{x}^a$ v uzlových bodech mřížky.
3. **Krátká předpověď** – Z výsledné analýzy se vypočítá krátkodobá předpověď, která se stává předběžným odhadem pro analýzu v dalším asimilačním okně ± 3 hod, se středem v čase 06 hod.

Jelikož asimilujeme v modelu pouze měřené hodnoty v časovém rozmezí asimilačního okna, označujeme tyto asimilační modely jako nespojitě.

Spojité asimilační modely

V dnešní době se preferuje více spojitá asimilace, která v ideálním případě asimiluje data ve stejný okamžik jako jsou naměřena. Tomuto způsobu asimilace se přibližují metody 4D, z nichž v praxi je implementována jako nejkompaktnější metoda 4DVAR. Výsledky těchto modelů jsou spojitě a fyzikálně i více realističtější.

1.2 Metody objektivní analýzy

Při zrodu numerické předpovědi počasí (NWP) byly počáteční podmínky získávány manuální analýzou meteorologických diagramů a pracnou interpolací do předem definovaných síťových bodů. Subjektivní analýza byla brzy nahrazena objektivními metodami jako metoda polynomiálního přiblížení a Cressmanova korekční metoda. Tyto metody ovšem nebyly příliš přesné, jelikož nevyužívaly optimálně dostupná data. Pokrok v objektivní analýze pokračoval po roce 1960, kdy Gandin (1963) navrhl techniku, založenou na principech *optimální interpolace* (OI). Jako počáteční hodnoty (předběžný odhad) sloužila krátká (6 hod) předpověď z předešlé analýzy. Výsledná analýza byla získána jako kompromis váhy měření a předběžného odhadu.

Se vzrůstajícím množstvím družicových měření se začaly projevovat nevýhody OI, a na řadu přišla nová metoda asimilace dat tzv. *variační metoda*, která je schopna asimilovat družicová data přímo v modelu a analyzovat atmosféru globálně. Zpočátku se variační metoda využívá pro výpočet vertikálních profilů parametrů z družicových dat v jednotlivých bodech sítě (1D-Var), ovšem v roce 1996 uvedlo Evropské centrum pro střednědobou předpověď (ECMWF) do provozu analýzu 3D-Var, řešící problém odhadu globálně. Metodu 3D o rok později rozšířilo o další dimenzi času, a do provozu se dostala 4D-Var analýza, u které byl vliv měřených dat v prostoru a čase řízený dynamikou modelu (zdroj [33]).

V současné době jsou pro výslednou analýzu užívány metody objektivní analýzy, které vycházejí z teorie optimálního odhadu. Zmíníme se také o zcela odlišné metodě objektivní analýzy, která je využívána především pro asimilaci radarových dat tzv. metodě *nudging*.

- Teorie optimálního odhadu:
 - Optimální interpolace
 - Variační metody 3D a 4D
- Nudging

1.2.1 Teorie optimálního odhadu v meteorologii

Tato metoda je nejjednodušším vyjádřením běžných algoritmů, používaných v dnešní meteorologii od 60. let 20. století. Optimální odhad získáme využitím lineární analýzy

v algebraické formě, a proto bývá také často nazýván *Best Linear Unbiased Estimator (BLUE)*.

Hlavním problémem je získat co nejlepší odhad počátečních podmínek na základě naměřených hodnot. Měřené hodnoty mají dimenzi p a můžeme je zapsat takto:

$$\mathbf{y} = H(\mathbf{x}_t) + \varepsilon_H + \varepsilon_o,$$

kde ε_o je chyba měření dat, daná přesností měřících přístrojů a ε_H je chyba spjatá s volbou operátoru H a chyba diskretizační (tj. \mathbf{x}_t není reálným stavem, ale pouze nejlepším možným přiblížením stavu atmosféry). Výsledek tohoto problému můžeme zpřesnit přeurčením systému, tzn. do počátečních hodnot zakombinujeme ještě další informaci o počátečním stavu atmosféry. Další dostupnou informací je využití odhadu krátkodobé modelové předpovědi, který jsme označili jako předběžný odhad. Ten má dimenzi n a můžeme jej zapsat takto:

$$\mathbf{x}_b = \mathbf{x}_t + \varepsilon_b,$$

kde ε_b je chyba předběžného odhadu. Je zřejmé, že pole předběžného odhadu můžeme vyjádřit ve stejném formalismu jako hodnoty měření, pouze datový operátor H je zde redukován, v důsledku shodné dimenze jako je výsledný odhad modelu, na jednotkovou matici I .

Je zřejmé, že problém by byl velmi jednoduchý v jednorozměrném případě, pokud ovšem máme měření více, chyby mezi měřeními, resp. chyby z předběžného odhadu, se mohou navzájem ovlivňovat, a k rozptylům nám přibudou navíc kovariance chyb. Komplexní popis chyb nám poskytují matice chyb předběžného odhadu \mathbf{B} a matice chyb měření \mathbf{R} , které můžeme zapsat takto [1]:

$$\mathbf{B} = E[(\varepsilon_{\mathbf{b}} - \overline{\varepsilon_{\mathbf{b}}})(\varepsilon_{\mathbf{b}} - \overline{\varepsilon_{\mathbf{b}}})^T]$$

$$\mathbf{R} = E[(\varepsilon_{\mathbf{o}} - \overline{\varepsilon_{\mathbf{o}}})(\varepsilon_{\mathbf{o}} - \overline{\varepsilon_{\mathbf{o}}})^T],$$

kde $\overline{\varepsilon_{\mathbf{b}}}$ a $\overline{\varepsilon_{\mathbf{o}}}$ jsou průměrné hodnoty chyb předběžného odhadu a měření.

Jedná se o čtvercové symetrické matice ($\mathbf{B} \in \mathbb{R}^{n \times n}$, $\mathbf{R} \in \mathbb{R}^{p \times p}$). Na diagonále $i = j$ obsahuje variační matice $cov(\varepsilon_i, \varepsilon_j) = var(\varepsilon_i)$ tzn. rozptyl jednotlivých komponent vektoru ε a mimo diagonálu $i \neq j$ $cov(\varepsilon_i, \varepsilon_j)$. Pro názornost tvar variační matice chyb předběžného odhadu \mathbf{B} :

$$\mathbf{B} = \begin{pmatrix} var(\varepsilon_1^b) & cov(\varepsilon_1^b, \varepsilon_2^b) & cov(\varepsilon_1^b, \varepsilon_3^b) & \dots \\ cov(\varepsilon_1^b, \varepsilon_2^b) & var(\varepsilon_2^b) & cov(\varepsilon_2^b, \varepsilon_3^b) & \dots \\ cov(\varepsilon_1^b, \varepsilon_3^b) & cov(\varepsilon_2^b, \varepsilon_3^b) & var(\varepsilon_3^b) & \dots \\ \vdots & \vdots & \vdots & \ddots \end{pmatrix} \quad (1.1)$$

Pokud chyby ε mají konečné druhé momenty a kladné rozptyly, jejich závislost můžeme měřit pomocí korelačního koeficientu (dle [8]):

$$\rho(\varepsilon_i, \varepsilon_j) = \frac{\text{cov}(\varepsilon_i, \varepsilon_j)}{\sqrt{\text{var}(\varepsilon_i)\text{var}(\varepsilon_j)}}$$

tj. platí, že chyby jsou nezávislé pokud [8]:

$$\rho(\varepsilon_i, \varepsilon_j) = \text{cov}(\varepsilon_i, \varepsilon_j) = 0$$

Cílem metody je získat optimální odhad pole fitováním současných naměřených hodnot a předběžného odhadu. Pro zjednodušení výpočtu optimálního odhadu analýzy, je důležité zavést vhodné předpoklady [1]:

- *Lineární datový operátor*: změny datového operátoru v okolí předběžného odhadu jsou lineární, tzn. pro $\forall \mathbf{x}$ dostatečně blízka \mathbf{x}_b , platí:

$$H(\mathbf{x}) - H(\mathbf{x}_b) = \mathbf{H}(\mathbf{x} - \mathbf{x}_b), \quad (1.2)$$

kde \mathbf{H} je lineární operátor.

- *Netriviálnost chyb*: \mathbf{B} a \mathbf{R} jsou pozitivně definitní matice
- *Model i měření nemají směrodatnou odchylku*: tzn. střední hodnota chyby předběžného odhadu a chyby měření je nula:

$$\overline{\mathbf{x}_b - \mathbf{x}_t} = \overline{\mathbf{y} - H(\mathbf{x}_t)} = 0$$

- *Nulová korelace chyb*: chyby měřených dat a chyby předběžného odhadu nejsou vzájemně korelované:

$$(\mathbf{x}_b - \mathbf{x}_t)(\mathbf{y} - H[\mathbf{x}_t])^T = 0$$

- *Lineární analýza*: hledáme analýzu s opravou na předběžný odhad, která závisí lineárně na odchylkách měřených dat od předběžného odhadu:

$$\mathbf{x}_a \sim \mathbf{y} - H[\mathbf{x}_b]$$

- *Optimální analýza*: hledáme analyzovaný stav, který je co možná nejbližže skutečnému stavu \mathbf{x}_t .

Výsledek metody nejmenších čtverců

Na základě výše zmíněných předpokladů a užitím netriviálního výpočtu (rigorózní odvození v [1]), můžeme výsledný optimální odhad, metodou nejmenších čtverců, vyjádřit ve tvaru *BLUE* rovnice [1]:

$$\mathbf{x}_a = \mathbf{x}_b + \mathbf{K}(\mathbf{y} - H[\mathbf{x}_b]) \quad (1.3)$$

$$\mathbf{K} = \mathbf{B}\mathbf{H}^T(\mathbf{H}\mathbf{B}\mathbf{H}^T + \mathbf{R})^{-1}, \quad (1.4)$$

kde lineární operátor \mathbf{K} je nazýván *váhová matice analýzy* (gain, weight matrix) a udává s jakou váhou přírůstek měření $\delta\mathbf{x} = \mathbf{y} - H[\mathbf{x}_b]$ přispěje k předběžnému odhadu (tzn. nakolik nám naměřená hodnota ovlivní výsledný namodelovaný stav pole \mathbf{x}_a).

Variační matice chyby analýzy je ve tvaru [1]:

$$\mathbf{A} = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B} \quad (1.5)$$

K výsledku optimálního odhadu \mathbf{x}_a lze dojít několika způsoby. Uvedu dva z nich, dobře popsané v [3]:

1. Minimalizací variance chyby odhadu – vstupní naměřené hodnoty a předběžný odhad jsou zatíženy chybami, které se projeví jako váhy pro získání výsledného odhadu. Tyto váhové koeficienty můžeme shromáždit v matici \mathbf{K}^{z° a pro výsledný odhad můžeme psát ve tvaru [3]:

$$\mathbf{x}_a = \mathbf{K}^{z^\circ} \begin{pmatrix} \mathbf{x}_b \\ \mathbf{y}_o \end{pmatrix}$$

Využitím dříve zmíněných předpokladů a minimalizací chyby odhadu jsme schopni tyto koeficienty určit a matici \mathbf{K}^{z° vyjádřit pomocí námi známých variačních matic chyb měření \mathbf{R} a předběžného odhadu \mathbf{B} .

2. Uvážíme-li, že chyby měřených dat a předběžného odhadu jsou distribuovány vícedimenzionální Gaussovou rozdělovací funkcí. Na základě předpokladu nulové korelace chyb, můžeme celkovou pravděpodobnost vyjádřit ve tvaru [3]:

$$p(\varepsilon_0, \varepsilon_b) \propto \exp\left\{-\frac{1}{2}\left((H[\mathbf{x}] - \mathbf{y})^T \mathbf{R}^{-1}(H[\mathbf{x}] - \mathbf{y}) + (\mathbf{x} - \mathbf{x}_b)^T \mathbf{B}^{-1}(\mathbf{x} - \mathbf{x}_b)\right)\right\}$$

Nejpravděpodobnější hodnota \mathbf{x} je taková, pro kterou je pravděpodobnost p maximální. Tento případ nastane, pokud minimalizujeme výraz v exponenciále, který značíme $J(\mathbf{x})$ a nazýváme *váhovou funkcí* (cost function)[3]:

$$J(\mathbf{x}_a) = \frac{1}{2}\left((H[\mathbf{x}] - \mathbf{y})^T \mathbf{R}^{-1}(H[\mathbf{x}] - \mathbf{y}) + (\mathbf{x} - \mathbf{x}_b)^T \mathbf{B}^{-1}(\mathbf{x} - \mathbf{x}_b)\right) \quad (1.6)$$

Jedná se o funkcionál, jehož vahami jsou matice \mathbf{B} a \mathbf{R} . Měří vzdálenost mezi předběžným odhadem a měřenými hodnotami. Váhovou funkci minimalizujeme spočtením gradientu a položením rovno nule [3]:

$$\nabla_{\mathbf{x}} J = \mathbf{B}^{-1}(\mathbf{x} - \mathbf{x}_b) + \mathbf{H}^T \mathbf{R}^{-1}(H[\mathbf{x}] - \mathbf{y}) \quad (1.7)$$

Odtud po několika úpravách získáme řešení analýzy (*BLUE analysis*) vyjádřené v rovnici (1.3).

Oba postupy jsou ekvivalentní a dovedou nás ke stejnému výsledku analyzovaného stavu \mathbf{x}_a . Dále bylo nutné zvolit metody, jak nejlépe rovnici *BLUE* odhadu řešit, zvláště s ohledem na to, že vektor řešení (tj. tlak, teplota, vítr ve všech uzlových bodech modelové mřížky) bývá řádu asi $10^6 - 10^7$. Právě způsobem řešení této rovnice se odlišují metody objektivní analýzy, které z teorie optimálního odhadu vychází.

Z *BLUE* rovnice (1.3) je zřejmé, že pro co nejoptimálnější odhad analýzy pole je nutné chyby měření a předběžného odhadu odhalit, kvantifikovat resp. pokud nejsou měřeny přímo, zavést taková omezení, která nám pomohou se reálným chybám alespoň přiblížit. Jelikož odhad těchto chyb není triviální, a pro výsledný odhad zásadní, seznámíme se s problematikou podrobněji.

1.2.2 Modelování matice chyb měření

Variance chyb měření

Jsou získány ze znalosti charakteristik měřících přístrojů. Obsahují i chybu reprezentace, která souvisí s chybou rozlišení předpovědního modelu. V případě, že hodnota měření je nadhodnocena (příp. podhodnocena) vlivem systematické chyby měřícího přístroje, mluvíme o *biasu* chyb (tzn. pro střední hodnotu chyby platí $E[\varepsilon] \neq 0$). Důležité je v praxi tyto biasy z měření (nebo datového operátoru H) vyřazovat, jinak nebude výsledná analýza optimální.

V modelovém systému jsou biasy pravidelně monitorovány a vyřazovány. U družic se biasy objevují často v důsledku vibrací nebo při přeměně měřených veličin na modelové veličiny. V tomto případě se hodnoty nevyřazují, ale provádí se nutné korekce biasu [33].

Korelace chyb měření

Z metody optimální interpolace, která je založena na výpočtu inverzní matice $(\mathbf{B} + \mathbf{R})^{-1}$ (viz. 1.8 níže), zjistíme, že pro řešení analýzy je důležité matici \mathbf{R} zjednodušit. Toho dosáhneme předpokladem nulové kovariance chyb, kdy nám matice přejde na snadněji řešitelný diagonální tvar.

Jelikož stanice bývají rozmístěny v dostatečné vzdálenosti mezi sebou, a měření z jednotlivých typů pozorování užívá jiných přístrojů, je předpoklad nezávislosti chyb z různých měření velmi dobře platný. Kovariance se často vyskytují u typů pozorování, která poskytují obrovské množství měřených dat, jako např. radiosondy, letadla a družice. Korelovaná pozorování se před použitím v modelu odstraní [1].

1.2.3 Modelování matice chyb předběžného odhadu

Tvar variační matice chyb předběžného odhadu \mathbf{B} řídí výsledek objektivní analýzy a je jejím základním kamenem v metodách optimální interpolace a 3D-Var. Vyskytují-li se rozdíly mezi předběžným odhadem a měřenými hodnotami v bodech měření, dostaneme observation increment, který pomocí metod objektivní analýzy rozšíříme do bodů

modelové mřížky. Informace o šíření a hlazení incrementu $\delta\mathbf{x}_a$ je obsažena v prostorové struktuře matice \mathbf{B} . Proto je důležité tuto matici podrobněji prozkoumat.

Pro zjednodušení situace nejprve budeme uvažovat případ jediného měření (např. teploty). Pokud předpokládáme, že chyby měření z různých míst uzlových bodů modelové mříže jsou nezávislé, matice \mathbf{B} nám přejde na diagonální tvar. Pro šíření informace z bodu modelové mříže předpokládáme silně omezující hypotézy: isotropie a homogenita šíření [11].

Pro vícerozměrný případ, kdy měříme všechny závislé meteorologické veličiny, obsahuje matice \mathbf{B} navíc mimo diagonálu kovariance chyb mezi těmito veličinami (vítr a geopotenciál, vítr a teplota. . .). Výpočet všech těchto kovariancí nám usnadňují základní rovnováhy v atmosféře: hydrostatická a geostrofická, které nám popisují vzájemné vztahy mezi veličinami [11]. Často bývají korelace chyb předepisovány analytickými funkcemi. Takoveto předpisy označujeme jako korelační modely a pro různou část glóbu bývají různé [2]

Variance a kovariance chyb předběžného odhadu jsou tedy důležitým zdrojem informací pro výsledné vytvoření modelového pole analysis incrementu. Matice \mathbf{B} bývá zpravidla počítána jako statistický soubor krátkých modelových předpovědí a v praxi se jejím řešením zabývají různé metody (např. NMC, ansámblová metoda, Hollingworthova-Lonbergova metoda, metoda adaptive filtering, adjoin sensitivity. . .) [1].

Metody odhadu matic \mathbf{B}

Hollingworth-Lonbergova metoda – užívá se především pro oblasti, kde je dostatečně hustá síť měření poskytující velké množství informací. Metoda užívá odchylek předpovědi (tedy pole předběžného odhadu) od naměřených hodnot, a na základě statistik poskytuje informace o kovarianci chyb předběžného odhadu. Platí [1]:

$$c(i, j) = \overline{(\mathbf{y}_i - \mathbf{H}_i \mathbf{x}_b)(\mathbf{y}_j - \mathbf{H}_j \mathbf{x}_b)^T},$$

kde $c(i, j)$ jsou kovariance matice \mathbf{B} spočtené v bodech měření i a j , \mathbf{y} jsou naměřené hodnoty, \mathbf{H} datový operátor a \mathbf{x}_b hodnoty předběžného odhadu.

NMC (National Meteorological Center) metoda – velmi populární a v současné době často užívaná metoda pro analýzu 3D-Var. Metoda nezávisí na měření, ale využívá rozdílů dvou předpovědí, v praxi většinou volených 24 hod a 48 hod. Časy jsou voleny tak, aby se setřely rozdílly mezi dnem a nocí, které by nám do výsledku vnášely chyby. Pro matici chyb předběžného odhadu platí přibližný vztah [12]:

$$\mathbf{B} \approx \alpha \overline{[X_f(48h) - X_f(24h)][X_f(48h) - X_f(24h)]^T},$$

kde $X_f(48h)$ resp. $X_f(24h)$ značí předpověď modelu na 48 hod resp. 24 hod.

Ansámblová metoda – nová metoda, která využívá ansámblové analýzy k odhadu chyb předběžného odhadu [12]. Pokud provedeme malé změny v počátečních podmínkách (tzv. perturbujeme) např. teploty a spustíme předpovědní model, získáme pro tyto perturbace různé předpovědi. Uvědomíme-li si, že se změnou závislé veličiny teploty se nám, díky platným fyzikálním zákonům v atmosféře, změní i ostatní meteorologické parametry (vlhkost, složky rychlosti větru, vlhkost...), získáme ve výsledku statistický soubor, na základě kterého spočítáme variance a kovariance chyb matice \mathbf{B} .

1.2.4 Optimální interpolace (OI)

Základní myšlenkou OI je algebraické zjednodušení výpočtu váhy \mathbf{K} v rovnicích analýzy (1.3) a (1.4). Zjednodušení dosáhneme lokálností metody, kdy pro každou proměnnou modelu je v určení analýzy důležitých pouze několik měření, která v principu poskytují v optimální analýze informace s velkou váhou (tj. taková, která mají významné kovariance chyb modelových proměnných). Výraz (1.3) poté můžeme přepsat do tvaru, který je jednodušší pro výpočet (dle [3]):

$$\mathbf{x}_a = \mathbf{x}_b + \mathbf{B}^{xy}(\mathbf{B}^{yy} + \mathbf{R})^{-1}(\mathbf{y} - H[\mathbf{x}_{b,o}]), \quad (1.8)$$

kde $\mathbf{x}_{b,o}$ je hodnota předběžného odhadu ve vybraných bodech měření, \mathbf{B}^{xy} resp. \mathbf{B}^{yy} popisují kovariance chyb předběžného odhadu (matice \mathbf{B}) mezi modelovými proměnnými \mathbf{x} a modelovým stavem interpolovaným do vybraných bodů měření resp. mezi body měření.

V praxi nejprve oblast rozdělíme na menší geometrické domény, v jejichž středu se nachází modelové proměnné a poté vybíráme měřená data uvnitř těchto domén. Bez lokálnosti metody OI, bychom nedokázali analýzu, vzhledem k obrovské dimenzi matic \mathbf{B}^{yy} a \mathbf{R} , dost dobře spočítat¹. Výběr měřených dat je často prováděn dvěma způsoby: pomocí síťových bodů nebo boxů.

Předpoklady pro výpočet OI:

- existuje spojitý korelační model chyb předběžného odhadu \mathbf{B} , který dovoluje matice \mathbf{B}^{xy} a \mathbf{B}^{yy} spočítat.
- datový operátor H , který interpoluje modelové hodnoty předběžného odhadu do vybraných bodů měření, musí být lineární. Předpoklad není splněn pro družicová pozorování, kde je nutná přeměna modelových parametrů na měřené záření.

Výhodou OI je jednoduchost provedení a její malé nároky. Nevýhodou jsou falešné šumy vznikající v poli analýzy z důvodu aplikování různých množin měření na různé části modelu. Omezením v přesnosti analýzy metodou OI je také předpoklad existence explicitní spojitě korelační funkce pro výpočet kovariancí matice \mathbf{B} .

¹Matice $\mathbf{B}^{yy} + \mathbf{R}$ je pozitivně definitní s omezením na vybrané body měření a má dimenzi $p \times p$, kde p (počet měření) bývá řádu 10^4 až 10^5 (viz. [3])

1.2.5 Tří-dimenzionální variační analýza (3D-Var)

Používá metodu variačního počtu pro řešení BLUE rovnice, a dovoluje nám tak se vyvarovat výpočtu váhové matice \mathbf{K} z rovnic (1.3) a (1.4). Statisticky optimálními cestami kombinuje měřená data a předběžný odhad a iterativní metodou řeší variační úlohu, globálně pro celý stavový vektor. Metoda spočívá v minimalizování funkcionálu $J(x)$ (*cost function*), který jsme již zavedli ve vztahu(1.6) [6]:

$$J(\mathbf{x}) = J_b(x) + J_o(x),$$

$$J(\mathbf{x}) = \frac{1}{2} \left((\mathbf{x} - \mathbf{x}_b)^T \mathbf{B}^{-1} (\mathbf{x} - \mathbf{x}_b) + (\mathbf{y} - H[\mathbf{x}])^T \mathbf{R}^{-1} (\mathbf{y} - H[\mathbf{x}]) \right)$$

$$\nabla_{\mathbf{x}_a} J = \mathbf{B}^{-1} (\mathbf{x}_a - \mathbf{x}_b) + \mathbf{H}^T \mathbf{R}^{-1} (H[\mathbf{x}_a] - \mathbf{y}) = 0,$$

kde \mathbf{x} je modelový stavový vektor, \mathbf{x}_a je zpřesňovaný stavový vektor výsledné analýzy, \mathbf{y} je vektor měřených hodnot, $J_b(\mathbf{x})$ a $J_o(\mathbf{x})$ jsou váhové funkce předběžného odhadu a měření.

Minimalizační problém můžeme také řešit se členy incrementu $\delta\mathbf{x}$. Platí [6]:

$$\delta\mathbf{x} = \mathbf{x} - \mathbf{x}_b,$$

$$J(\delta\mathbf{x}) = \frac{1}{2} \left(\delta\mathbf{x}^T \mathbf{B}^{-1} \delta\mathbf{x} + (\mathbf{H}\delta\mathbf{x} - \mathbf{d})^T \mathbf{R}^{-1} (\mathbf{H}\delta\mathbf{x} - \mathbf{d}) \right), \quad (1.9)$$

$$\mathbf{d} = \mathbf{y} - H(\mathbf{x}_b),$$

$$\nabla J = \mathbf{B}^{-1} \delta\mathbf{x} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H} \delta\mathbf{x} - \mathbf{H}^T \mathbf{R}^{-1} \mathbf{d}, \quad (1.10)$$

kde analýza je hledána součtem předběžného odhadu a analysis incrementu $\delta\mathbf{x}_a$,

$$\mathbf{x}_a = \mathbf{x}_b + \delta\mathbf{x}_a$$

Přírůstek $\delta\mathbf{x}_a$ najdeme minimalizací váhové funkce (1.9), užitím gradientu váhové funkce (1.10) a vhodného minimalizačního algoritmu. V rovnici (1.9) a (1.10) jsme využili předpokladu lineární aproximace (1.2) rozdílu [6]:

$$H(\mathbf{x}) - H(\mathbf{x}_b) = \mathbf{H}\delta\mathbf{x},$$

kde $H(\mathbf{x})$ je nelineární datový operátor a \mathbf{H} je jeho lineární aproximace. \mathbf{H}^T nazýváme adjungovaný operátor.

Počet opakování je v praxi pouze velmi malý, kdy minimalizace je zastavena při předem definovaném počtu opakování, případně při daném požadavku poklesu normy gradientu $\|J(\mathbf{x})\|$, která vyjadřuje míru, nakolik je analýza blízko minimu, než je počáteční bod minimalizace [1].

Velmi důležitý pro 3D-Var je model matice \mathbf{B} , která nám řádně definuje kovariance chyb předběžného odhadu pro všechny páry modelových proměnných. Kovariance chyb měření matice \mathbf{R} jsou ve většině případů nulové (nepředpokládáme korelaci chyb měření mezi nezávislou sítí měření, měření různých platforem nebo přístrojů). Důsledkem

blokově diagonální matice \mathbf{R} je, že J_o je součtem skalárních váhových funkcí $J_{o,i}$, každá z nich definovaná submaticí \mathbf{R}_i a odpovídající podmnožinou datových operátorů H_i a měřených hodnot \mathbf{y}_i . Dle [1]:

$$J_o = \sum_{i=1}^N J_{o,i}(\mathbf{x}) \quad J_{o,i} = (\mathbf{y}_i - H_i[\mathbf{x}])^T \mathbf{R}_i^{-1} (\mathbf{y}_i - H_i[\mathbf{x}])$$

Selhání J_o je užitečným diagnostickým nástrojem chování metody 3D-Var pro různé typy měření (velikost jednotlivých $J_{o,i}$ nám odhalí měření, která jsou nevhodná pro analýzu). Další výhodou je zjednodušení kódování výpočtu J_o a jeho gradientu a schopnost prosadit slabá vnější omezení, kterými jsou rovnovážné vlastnosti atmosféry [1].

1.2.6 Čtyř-dimenzionální variační analýza (4D-Var)

Je v principu zobecněním 3D-Var analýzy pro data měřená v různých časech. Zavádíme zde časové asimilační okno (assimilation time window), což je časový interval s kroky t_i , $i = 1, \dots, n$ (v praxi často voleny po 1 hodině), v nichž je počítána analýza modelu. Váhová funkce má nyní tvar (dle [1]):

$$J(\mathbf{x}) = J_b + J_o = \frac{1}{2}(\mathbf{x} - \mathbf{x}_b)^T \mathbf{B}^{-1}(\mathbf{x} - \mathbf{x}_b) + \frac{1}{2} \sum_{i=1}^n (H_i[\mathbf{x}_i] - \mathbf{y}_i)^T \mathbf{R}_i^{-1} (H_i[\mathbf{x}_i] - \mathbf{y}_i) \quad (1.11)$$

, kde \mathbf{x} je stavový vektor na počátku startu modelu v čase t_o a \mathbf{x}_i je stavový vektor v čase t_i jako předpověď modelu. Dále \mathbf{y}_i a \mathbf{x}_{ti} jsou měření a skutečný stav v čase t_i a \mathbf{R}_i je variační matice pro chyby měření $\mathbf{y}_i - H_i(\mathbf{x}_{ti})$.

Datový operátor H_i pro měření \mathbf{y}_i v čase i je linearizovaný jako \mathbf{H}_i . Variační matice chyb \mathbf{B} je definována pouze v počátečním čase, ve kterém je také předem zadaný předběžný odhad \mathbf{x}_b a analýza \mathbf{x}_a .

Co se týče první části váhové funkce J_b , počítáme ji podobně jako u metody 3D-Var. Komplikovanější je výpočet druhé části J_o , která vyžaduje n -integrací předpovědního modelu v jednotlivých časech t_i , $i = 1, \dots, n$, a proto pro zjednodušení jejího výpočtu zavádíme několik následujících podstatných předpokladů.

1. Měření jsou seskupena v čase a poté jsou asimilační časová okna rozdělena na menší podokna se šířkou 1 hodiny². Pro asimilaci v daném čase jsou vybrána všechna měření z různých platforem, která jsou co nejbližší centru podokna (předpokládáme malé změny v stavu modelu \mathbf{x}) [7].
2. Zavádíme linearizovaný operátor zobrazení M_i (TL, *tangent linear model*), který převede stavový vektor \mathbf{x}_i v čase vpřed z prostoru časového kroku i do prostoru časového kroku $i + 1$. S využitím předpokladů linearizace:

$$M_i(\mathbf{x}_b \delta \mathbf{x}) = M_i(\mathbf{x}_b) + M_i(\delta \mathbf{x})$$

²Délky časových intervalů se pro každý model liší. Zdrojem uvedených hodnot je [7]

a uvažíme-li předpoklad [20]:

$$\delta \mathbf{x}_i = M'_i \delta \mathbf{x}_{i-1} = \underbrace{M'_i M'_{i-1} \dots M'_0}_{M'^T[t_i, t_0]} \delta \mathbf{x}_0, \quad (1.12)$$

kde M'_i označujeme jako tzv. *tangent linear model* (TL).

Pro gradient váhové funkce (1.11) můžeme psát [20]:

$$\nabla_{\delta \mathbf{x}_0} J = B^{-1} \delta \mathbf{x}_0 + \sum_{i=1}^n M'^T[t_i, t_0] \mathbf{H}_i'^T R^{-1} (\mathbf{H}_i' \delta \mathbf{x}_i - d_i), \quad (1.13)$$

$$d_i = \mathbf{R}_i^{-1} (\mathbf{y}_i - H_i[\mathbf{x}_i]),$$

kde M'^T nazýváme tzv. adjungované zobrazení TL modelu (AD, *adjoint model*).

Nastavením počáteční podmínky $\delta \mathbf{x}_0 = 0$ řešíme rovnici (1.13) zpětnou integrací AD modelu, který nám pomůže dopravit zpátky v čase všechny příspěvky ke gradientu J_o na začátek okna, a tím získat nový modelový stav, dávající žádaný výsledek. Nový increment $\delta \mathbf{x}_0$ znovu dosadíme do rovnice (1.13) a počítáme gradient nové váhové funkce iteračními metodami, dokud nedosáhneme, v ideálním případě, podmínky $\nabla_{\delta \mathbf{x}_0} J = 0$. Každý nový odhad stavu modelu vyžaduje v principu nový běh předpovědního modelu, a navíc hledání stavů modelu ve všech časech t_i . To je v praxi velmi náročné na výpočetní techniku, a proto je v praxi iterace zastavena pokud $\|\nabla J\| \leq \varepsilon$, kde ε je předem definované malé číslo.

Poté na základě podmínky TL modelu (1.12) můžeme vypočítat modelové hodnoty \mathbf{x}_i v časech t_i [20].

Charakteristiky metody 4D-Var:

- pracuje pouze za předpokladu perfektního modelu (tj. malých modelových chyb)
- vyžaduje realizaci AD modelu $M_i'^T$ operátoru
- je optimálním asimilačním algoritmem přes časovou periodu \Rightarrow využívá jednotlivá měření stejně dobře, i když variační matice chyb předběžného odhadu \mathbf{B} není perfektní
- vysoká frekvence měření se stává hodnotnou pro výslednou analýzu

1.2.7 Nudging

Je čtyřdimenzionální asimilační procedura, s jejíž pomocí jsou modelové proměnné co nejvíce přibližovány k hodnotám meteorologických měření. Modelovou rovnici ve tvaru [4]:

$$\frac{\partial v}{\partial t} = F(v), \quad (1.14)$$

kde v je stavová proměnná ($T, u, v, q \dots$) a t je čas, doplňujeme o korekční člen (nudging člen), který se nám snaží přiblížit modelový stav skutečnému měřenému stavu atmosféry.

Důležitým požadavkem na model je, aby toto numerické řešení modelu, přinejmenším alespoň částečně, splňovalo dynamickou konzistenci s měřeními. Pokud máme tedy dostupná měřená data (například ze síťových radarových měření), interpolujeme je do modelové sítě a provádíme analýzu. Přepíšeme-li rovnici (1.14) s korekčním členem na pravé straně, dostaneme pro dynamický model vyjádření [4]:

$$\frac{\partial v}{\partial t} = F(v, \mathbf{x}, t) + GW(\mathbf{x}, t)\varepsilon(\mathbf{x})(v_o - v), \quad (1.15)$$

kde nudging člen je úměrný rozdílu mezi modelovým řešením v a měřeným stavem v_o . Dále v rovnici $\mathbf{x} = (x, y, z)^T$ jsou kartézské souřadnice, G určuje sílu nudging členu s ohledem na fyzikální silový člen F . $W(\mathbf{x}, t)$ jsou váhy jako funkce prostoru a času a $\varepsilon \leq 1$ je faktor, který odráží přesnost měření.

Celá integrační doba modelu je rozdělena na časové intervaly asimilace a předpovědi. Nudging člen bývá aktivní pouze po určitou asimilační dobu a poté je nudging člen „vypnut“ a modelová rovnice je integrována v podobě (1.14) [13].

Mezi výhody metody nudging patří [5]:

- početně více ekonomická než variační metody
- koeficienty u nudgingu mohou být optimalizovány variačními metodami
- metoda nudging a její modifikace jsou dosud úspěšně používány například v modelech s vysokým rozlišením a pro asimilaci radarových dat.

Nevýhodou metody je, že korekční člen v rovnicích může narušit základní fyzikální rovnováhy, na kterých bývá obvykle model založen a fakt, že nevyužívá data optimálně.

Kapitola 2

Meteorologická pozorování

Meteorologické pozorování můžeme dle [9] zadefinovat jako:

získávání kvantitativního popř. kvalitativního údaje, o jednom nebo více meteorologických prvcích a jevech. Pozorování jsou poskytnuta v určitém okamžiku na stálých meteorologických stanicích s různým vybavením. Součástí těchto pozorování jsou meteorologická měření, kdy zjišťujeme hodnoty meteorologických prvků pomocí vhodné měřicí techniky.

A právě přesná meteorologická měření jsou základním kamenem pro numerické předpovědní modely, s jejichž objektivními metodami analýzy atmosféry jsme se seznámili v první kapitole. Díky nim dokáží výkonné počítače vytvořit úspěšnou analýzu atmosféry a předpovědět její budoucí chování.

Světová meteorologická organizace (WMO, *The World Meteorological Organization*) je specializovanou světovou organizací, která byla ustanovená v roce 1951 za cílem podpory spolupráce meteorologických, klimatologických, hydrologických a jiných institucí. V současné době probíhá výměna, zpracování a přenos dat poskytnutých ze 188 členských zemí. WMO poskytuje 10 služeb, z nichž pro meteorologická pozorování jsou nejdůležitější: Světová služba počasí (WWW, *the World Wather Watch*) a služba zaměřená na družicová pozorování (The WMO Space Programme SAT).

Světová služba počasí (WWW) zabezpečuje dostupnost meteorologických informací pro operativní nebo výzkumné účely a má následující části [2]:

- světový systém pozorování (GOS, *the Global Observing System*)
- světový systém pro zpracování dat (GDPS, *the Global Data Processing System*)
- světový telekomunikační systém (GPS, *the Global Telecommunications System*)

Kontrola sítě všech typů pozorování je zároveň cílem systému pozorování GOS, který v současné době poskytuje každých 12 hodin přibližně 75 mil hodnot ze všech měření po celém světě, z nichž asi 98% pochází z družic viz. [33]. Mnoho z těchto měření

je dále využíváno pro analýzu, ovšem nemalé procento jich je při procesu kontroly kvality vyřazeno. Blíže se seznámíme s kontrolními systémy v samostatné kapitole využití pozorování v asimilaci.

2.1 Základní typy meteorologických pozorování

Pozorování můžeme v základní rovině rozdělit (dle [9]) podle místa na pozemní, lodní, letadlové, družicové a podle výšky nad terénem na přízemní a výškové. Mezi pozemní pozorování dále řadíme pozorování radarová a aerologická¹.

Zpracování meteorologických dat Pozemní, aerologická a lodní měření jsou často označována za konvenční. Pozorovatel v meteorologických stanicích zpracuje hrubá data, případně provádí korekci na místní efekty a kontroluje jejich vnitřní konzistenci. Poté jsou data zakódována do speciálních zpráv, vhodných pro telekomunikační přenos. Tyto zprávy používají mezinárodní označení a jsou z meteorologických stanic zasílána do regionálního centra, dále do národního a světového meteorologického centra. Informace ze všech stanic jsou sesbírána, dekodována, zkontrolována, archivována a šířena dále. Tento proces získání kompletního souboru pozorování z celého světa zabere až několik hodin po čase změření [2].

Pozemní pozorování

Meteorologické stanice Zahrnují meteorologická měření prováděná s pomocí meteorologických přístrojů, jejichž čidla jsou pevně spojená se zemí. V dnešní době provádí pozemní měření minimálně každé 3 hodiny, přibližně 11000 stanic rozmístěných po celé zemi [21]. Tyto informace jsou dále zakódovány do meteorologické zprávy *SYNOP*, která je odesílána do Světové meteorologické organizace. Tato zpráva obsahuje kromě identifikační sekce (den, hodina aj.) údaje o meteorologické dohlednosti, oblačnosti, změnách tlaku, o stavu a průběhu počasí, ale pro NWP analýzu se v současné době užívá zejména měření *atmosférického tlaku, rychlosti a směru větru, teplotě a relativní vlhkosti vzduchu*.

Aerologická pozorování Patří sem meteorologická měření významných dějů a parametrů v mezní vrstvě atmosféry a ve volné atmosféře. Měření jsou prováděna pomocí radiosond, vybavených balónem, která měří pomocí čidel *tlak, teplotu a vlhkost* až do výšek 30km. Měřená data jsou vybírána ze standardních tlakových hladin, resp. význačných hladin profilů teploty a větru. K lokalizaci sondy během letu je využíván navigační systém, který současně slouží k nepřímému měření *rychlosti a směru větru* (přepočítáno pozemním zařízením z informace o poloze radiosondy). Měřená data jsou

¹Co se týče terminologie budu se již dále vyjadřovat o meteorologických měřeních, která jsou (jakožto technicky měřené hodnoty) z hlediska pozorování pro numerickou část modelové předpovědi významnější.

zakódována do meteorologické zprávy *TEMP*. Informace pouze o směru a rychlosti větru jsou šifrovány do zprávy *PILOT* [22].

V současné době je provozováno zhruba 900 radio-sondážních stanic po celém světě, přičemž u více než 70% stanic je měření prováděno v 00 a 12 UTC. Asi 10-20% stanic provádí tato měření jednou denně. Na moři je tímto pozorovacím systémem vybaveno asi 15 lodí [21].

Letecká pozorování

Vzhledem k nedostatečnému počtu radiosondážních stanic (převážně nad mořem), se užívá letecká pozorování jako doplněk k aerologickým a družicovým pozorováním vyšších vrstev. Tento způsob pozorování dramaticky vzrůstá, jelikož poskytuje měření z oblastí, kde je málo radiosondážních dat a je kvalitativně s nimi srovnatelný.

Letadla jsou vybavena systémy ACARS (*Aircraft Communication Addressing and Reporting System*) resp. ASDAR (*Aircraft to Satellite Data Relay*), které ihned vysílají data pro zpracování a následný přenos. Tyto systémy také obsluhují senzory, které jsou schopny měřit tlak, teplotu a směr větru v dané letové hladině, případně při výstupu či sestupu letadla, i pro jiné vybrané hladiny. Některá letadla jsou dále vybavena senzory pro měření relativní vlhkosti, či senzory pro detekci seskupení ledových krystalků v dané hladině. Rychlost větru, tlaková hladina či statická teplota závisí především na letových vlastnostech, a jsou proto nepřímo určena z letového navigačního systému [21].

Automatický systém AMDAR (*Aircraft Meteorological Data Relay*), který shromažďuje měřená data a okamžitě je odesílá k dalšímu zpracování, poskytuje informace především o rychlosti, směru větru a teplotě [21].

Lodní pozorování

Meteorologická pozorování na palubě lodi, jsou součástí Světového systému pozorování oceánů (GOOS, *The Global Ocean Observing System*), sponzorovaného především Světovou meteorologickou organizací. Námořní doprava je v dnešní době již pouze doplňkem pozorování na moři, jelikož z velké části byla nahrazena prudkým nástupem družicových pozorování.

Měření se provádí při hladině (na lodích i pod hladinou) moře. Poskytují informace především o *teplotě, rychlosti a směru větru, tlaku a relativní vlhkosti*. Některé lodě jsou navíc vybaveny aerologickou sondáží. Na moři je v současné době asi 7000 lodí (asi 40% z nich poskytuje ve vybraný čas data - *SHIP*) [21], dále sem řadíme volně plující a kotvené bóje a nehybné plošiny.

Radiolokační pozorování

Meteorologické radiolokátory slouží, mimo jiné, ke zjišťování okamžitých intenzit atmosférických srážek a poskytují přehled o pohybu a struktuře srážkového systému. Měření

jsou založena na schopnosti srážkových částic v atmosféře rozptylovat mikrovlnné záření, vysílané radarem v pravidelných pulzech.

Obvyklý interval měření bývá 10-15 min s horizontálním rozlišením 2×2 km, vertikálním rozlišením 1km a dosahem měření asi 250 km, kdy se přesnost radaru s rostoucí vzdáleností měření od radaru zhoršuje [34].

Radarová měření díky plošnému pokrytí a dobrému prostorovému i časovému rozlišení dat vhodně doplňují síť pozemních stanic i družicová pozorování a stejně velký potenciál poskytují i pro analýzu ve vysokém rozlišení, která je v současné době předmětem výzkumu.

V meteorologii se také využívá dopplerovského radiolokátoru, který je určen zejména k měření radiálních rychlostí využitím Dopplerova efektu, tj. posun frekvence odraženého elektromagnetického záření od pohyblivých cílů. Pomocí radiolokátoru se měří, mimo jiné, spektrální rozložení velikosti kapek, popř. tuhých částic v atmosféře, profily rychlostí jejich pohybu, turbulence, stříh větru a jiné [9]. Pro asimilaci dat v NWP modelech se využívá informace o *rychlosti a směru větru* ve vysokém rozlišení, která bývá zakódována ve zprávě *PROFILER*.

2.1.1 Družicová pozorování

Družicová měření nejsou natolik přesná jako měření radiosondážní či letecká, ovšem jejich obrovskou výhodou je jejich široké geografické pokrytí. Družice poskytují měření nejen na zemském povrchu, ale i vertikálních profilů, a proto jsou pro numerickou předpověď nedocenitelným nástrojem.

Éra družic započala v roce 1960, kdy byla na oběžnou dráhu vyslána družice Tiros-1 [17]. Od té doby prošly družice obrovským vývojem, a především v posledních 5-10 letech byl zaznamenán významný nárůst ve kvantitě, kvalitě a rozmanitosti způsobu měření stavu atmosféry.

Družicová pozorování jsou součástí Světové služby počasí, jejíž družicová část světového systému pozorování GOS provádí kontrolu v současné době operativních družicových systémů a je podporována kosmickým programem Světové meteorologické organizace ve spolupráci s CGMS (*The Coordination Group for Meteorological Satellites*). Cílem CGMS je sběr, šíření a využití družicových dat, která jsou jádrem informačního systému Světové meteorologické organizace a snaha o zefektivnění využití družicových dat a produktů [28].

Základní rozdělení družic

Obecně můžeme družice rozdělit na 2 typy:

LEO (*Low Earth Orbit*) – družice s nízkou oběžnou dráhou jsou jedny z prvních meteorologických družic. Jsou většinou na přibližně kruhových oběžných drahách se střední výškou nad povrchem Země v rozmezí od 600 do 1500 km, oběžnou

dobou v rozmezí od 97 do 116 min a sklonem oběžné dráhy (vůči rovině rovníku) v rozmezí od 81 do 103 stupňů. Jsou schopny díky nízké výšce nad Zemí pokrýt celé mikrovlnné spektrum a poskytnout globální pokrytí průměrně v 3 hodinových intervalech.

GEO (*Geostacionary*) – geostacionární družice jsou umístěny na kruhové dráze v rovině rovníku ve výši přibližně 36 000 km nad povrchem Země, s oběžnou dobou 24 hodin. Protože družice má při svém oběhu nad rovníkem stejnou úhlovou rychlost jako Země, zůstává stále nad stejným bodem zemského povrchu (je „stacionární“). Družice tedy nepokrývají celou planetu jako družice polární, ovšem mohou časově podrobně sledovat vývoj oblačnosti nad stejnou oblastí, téměř nad celou polokoulí.

Družicová část globálního systému pozorování GOS zahrnuje kromě družic LEO a GEO ještě družice výzkumné tzv. R&D (*Research and Development*) [28]. Tyto družice jsou součástí výzkumného programu družic a palubních přístrojů. Jejich cílem je výzkum v oblasti měření dat v operativní nebo dosud neprozkoumané oblasti meteorologie a ke zjištění nových schopností měření, které mohou být později využívány v dlouhodobé operativní činnosti. Data z těchto družic jsou tedy pouze krátkodobá, bez záruky na dostupnost a kvalitu, přesto jsou v meteorologii využívána.

Agentury zabývající se družicovými systémy

Družice jsou převážně řízeny agenturami, které družice vytvořily a vyslaly na oběžnou dráhu. Tyto agentury se často zabývají nejen obsluhou a řízením družic, ovšem i výzkumnou činností v oblasti nových družic, družicových přístrojů, případně produktů ke zpracování dat. Zpravidla tedy bývá nová družice výsledkem spolupráce více agentur. Z nejvýznamnějších operativních a výzkumných agentur v oblasti družic zmíníme:

- NOAA (*National Oceanic and Atmospheric Administration*) – je vědecká agentura Spojených států, která vznikla v roce 1970 a obsluhuje 5 hlavních organizací, z nichž organizace NESDIS (*The National Environmental Satellite, Data and Information Service*) byla vytvořena k řízení družicového programu a shromáždění dat v datových centrech. Předmětem činnosti je operace, rozvoj, výzkum družic a zpracování a šíření jejich dat. NESDIS obsluhuje jak družice geostacionární (GOES, *Geostationary Operational Environmental Satellite*), tak polární (POES, *Polar Operational Environmental Satellite*) [29].
- EUMETSAT (*Europe's Meteorological Satellite Organisation*) – je evropská organizace, zabývající se vývojem a provozem meteorologických družic. Organizace byla vyčleněna, v roce 1986 z kosmické agentury ESA, s jasným cílem provozu evropských družic. V současné době sdružuje 21 členských států a 9 spolupracujících členských států, mezi něž patří i Česká republika [23].

Do oblasti družicového pozorování jsou zapojeny a podílí se také kosmické agentury Ruska, Číny, Indie aj. Zmíníme také významné agentury, které se zaměřují především na kosmických výzkum a vývoj. Patří sem evropská kosmická agentura ESA (*The European Space Agency*), americká kosmická agentura NASA (*National Aeronautics and Space Administration*), japonská výzkumná agentura NASDA (*Japan Exploration Agency*) a jiné.

Přehled družic

Přehled vybraných geostacionárních, polárních a výzkumných družic, které se významně podílí na asimilaci dat v předpovědních modelech, je uveden v tabulkách 2.1, 2.2, 2.3. Informace o družicích jsou převzaty ze stránek WMO [28].

V přehledu uvádím také stav družice, který označuje, zda-li je družice operativní (měřená data jsou z družice přijímána a zpracována) nebo záložní (data z družice nejsou využívána, družice se stává operativní v případě vyřazení dosavadní operativní družice z provozu).

Tabulka 2.1: Přehled některých geostacionárních družic GEO, přispívajících ke GOS

Družice	Agentura	Stav družice
MTSAT-1R	NASDA(Japonsko)	operativní
MTSAT-2	NASDA(Japonsko)	záložní
GOES 10, 11, 12	NOAA(USA)	operativní
GOES-13	NOAA(USA)	záložní
Meteosat-7, 9	EUMETSAT	operativní
Meteosat-6, 8	EUMETSAT	záložní
FY-2C	CMA(Čína)	operativní
FY-2D	CMA(Čína)	záložní
Kalpana-1	ISRO(Indie)	operativní
INSAT-3A	ISRO(Indie)	operativní

Tabulka 2.2: Přehled některých polárních družic LEO, přispívajících ke GOS

Družice	Agentura	Stav družice
NOAA-17, 18	NOAA(USA)	operativní
NOAA-15, 16	NOAA(USA)	záložní
NOAA-12	NOAA(USA)	omezená dostupnost
DMSP-F13, 16, 17	NOAA(USA)	operativní
DMSP-14, 15	NOAA(USA)	záložní
METOP-A	EUMETSAT	operativní
FY-1D	CMA(Čína)	operativní

Tabulka 2.3: Přehled některých výzkumných družic R&D, přispívajících ke GOS

Družice	Agentura
ERS-2	ESA
ENVISAT	ESA
TRMM	JAXA/NASA
QuickSCAT	NASA
Terra	NASA
GRACE	NASA/DLR
Aqua	NASA
CloudSat	NASA/CSA

Družicová měření

Družicová měření jsou často označována za měření nekonvenční. Od dat z konvenčních pozorování se odlišují tím, že družice neměří přímo teplotu, vlhkost ani vítr, ale měří záření, které je vyzařováno ze zemského povrchu nebo atmosférou, a dosáhne nejvyšších vrstev atmosféry, tzv. radiance. Záření je spjato s meteorologickými proměnnými pomocí tzv. *rovnice radiačního přenosu* (radiative transfer equation) [18].

Již v úvodu jsme zmiňovali datový operátor H , který vytváří přechod z prostoru modelových proměnných n do prostoru pozorování dimenze p . Tento operátor v případě konvenčních pozorování většinou zahrnoval pouze interpolaci a byl snadno linearizovatelný, ovšem v případě družicových měření zahrnuje vedle interpolace i rovnici radiačního přenosu, která není lineární.

To v praxi limitovalo přímou asimilaci radiancí metodou OI, která vyžaduje lineární operátor H , a asimilovány byly pouze vertikální profily (případně vlhkostní), odvozené z radiancí, řešením rovnice:

$$\mathbf{x} = H^T(\mathbf{y}), \quad (2.1)$$

kde \mathbf{x} představuje profil teploty (případně vlhkosti), \mathbf{y} měření radiancí a H^T je inverzní

datový operátor, tj. $H.H^T = \mathbf{I}$, který umožňuje zobrazení z prostoru měření do prostoru modelových parametrů.

Řešení této úlohy 2.1 však není jednoznačné a obvykle je nutné využít informace předběžného odhadu. Metodami řešení tohoto problému se zabývají speciální algoritmy (tzv. retrieval algorithm), které využívají např. regresní metody, 1DVAR metody a jiné [18], jejichž podrobný popis přesahuje rámec této práce.

Uživatelé často, ke zpracování družicových dat, využívají uživatelských balíčků, které z družicových měření počítají přímo významné meteorologické parametry. Tyto balíčky jsou výsledkem středisek pro zpracování družicových dat SAF (*Satellite Application Facility*). V případě přechodu z družicových dat k meteorologickým veličinám můžeme využít např. balíčků RTTOV (*Radiative transfer model and profile datasets*), AAPP (*ATOVS and AVHRR Pre-processing Package*), SSMIS_PP (*The SSMIS Pre-processing Package*) a jiné [25].

Základní rozdělení měření

Měření a družicové přístroje rozdělíme podle [10] na:

- **Pasivní přístroje** – tzv. radiometry, umožňují měřit záření vyzářené zemským povrchem nebo atmosférou (resp. sluneční záření odražené od povrchu/atmosféry) v několika oborech vlnových délek (kanálech), obvykle zahrnujících oblast viditelného a infračerveného (IR) záření. Podle cíle měření se kanály liší pro [18]:
 - *sondáž atmosféry* – kanály se nacházejí v částech IR a mikrovlnného spektra, pro které je hlavním příspěvkem měření záření z atmosféry. Primárně jsou užívány k získávání informací o teplotě a vlhkosti atmosféry.
 - *snímání záření emitovaného zemským povrchem* – kanály měří emisivitu zemského povrchu v oblasti atmosférických oken (tj. míst, kde měření emisivity není ovlivňováno atmosférou) v IR a mikrovlnném spektru. Primárně se užívá k získání teploty zemského povrchu a veličin, které vyzařování zemského povrchu ovlivňují, tzn. vítr (oceány) a vegetace (na Zemi). U geostacionárních družic (Meteosat, MTSAT a GOES) a polárních družic (AQUA, Terra), mohou být také kanály IR, viditelného a mikrovlnného spektra užity k získání informace o oblačnosti/dešti a pohybu oblaků a z nich odvozených informací o směru a rychlosti větru (AMV, *Atmospheric Motion Vectors*).
- **Aktivní přístroje** – zařízení, která vysílají záření a měří, kolik se ho odrazí nebo rozptýlí zemským povrchem/atmosférou zpět. Jedná se o relativně nový směr využití družicového měření a řadíme sem techniky:
 - *Snímání zemského povrchu* – tyto tzv. skaterometry aktivně ozařují zemský povrch v oblasti oken a přijímají zpětné záření, rozptýlené na rozvlněné

hladině oceánů a moří. Primárně tak poskytují informace o větru poblíž hladin oceánů [18].

- *Radarové přístroje na družicích* – využívají silných vlnových pulzů, které se na Zemi odráží zpět a jsou zachyceny anténou na družici. Řadíme sem např. SAR (*Synthetic Aperture Radar*) umístěný na družici ERS-2 a radar ASAR (*Advanced Synthetic Aperture Radar*) na palubě družice ENVISAT. Přístroje poskytují snímky oceánů, Země a ledu ve vysoké rozlišení [27].
- *Technika radio occultation (RO)* – je založena na měření ohybu (refakci) rádiových signálů, při průchodu atmosférou, ze kterého lze odvodit informace o teplotě a vlhkosti v atmosféře. Tato technika užívá navigačního systému GNSS (*Global Navigation Satellite system*), který v současné době tvoří 24 družic. Přijímače jsou umístěny na družicích s nízkou oběžnou dráhou letu LEO a poskytují profily teploty a vlhkosti atmosféry ve vysokém rozlišení a téměř v reálném čase. RO techniky využívají družice CHAMP, GRACE, COSMIC/FORMOSAT-3 a MetOp-A [26].
- *Doppler Wind Lidar (DWL)* – je přístroj, který vysílá laserové pulsy o vlnové délce $\lambda = 355\text{nm}$ směrem k atmosféře. Na molekulách a částicích v různých vrstvách atmosféry dochází ke zpětnému rozptylu a na základě Dopplerova frekvenčního posunu navraceného signálu jsme schopni určit rychlostní profily větru s rozlišením: 500 m pod 2 km, 1000 m do 16 km a 2000 m ve vrstvách 16 až 20 km [10].

Přehled měřicích přístrojů

Měřicí přístroje rozdělíme podle předchozího dělení na pasivní a aktivní. Uvádím zde pouze vybrané družicové přístroje, které jsou nejvíce využívány v asimilaci dat v předpovědních modelech. Jejich stručný přehled (viz. také [28]) je nakonec uveden v tabulce (2.4).

Pasivní družicové přístroje

SEVIRI (*Spinning Enhanced Visible InfraRed Imager*) – 12 kanálový radiometr, který snímá záření ve viditelném a IR spektru. Radiometr využívá 11 úzkopásmových a 1 širokopásmový spektrální kanál. Je umístěn na geostacionární družici MSG a poskytuje informace každých 15 minut s rozlišovací schopností (projekce 1 obrazového pixelu na zemský povrch v nadiru, tj. poddružicový bod [9]) 1 km pro kanál HRV a 3 km pro všechny ostatní kanály. S rostoucí vzdáleností od nadiru se rozlišovací schopnost snižuje [16].

Vedle obrazových dat z přístroje SEVIRI, jsou z družice MSG k dispozici další operativní produkty, generované ve zpracovatelském pozemním středisku, distribuované organizací EUMETSAT. Uvedu pouze některé z nich (pro jednoznačnost v angličtině) [16]:

- *Atmospheric Wind Vectors* – vektory větru, získané analýzou pohybu oblačnosti a plynných složek atmosféry (vodní pára, ozón) v různých hladinách
- *Cloud Analysis* – analýza oblačnosti; informace o množství oblačnosti (pokrytí), výšce a typu oblačnosti v různých hladinách. Určeno pro využití v NWP modelech a pro klimatické účely
- *Tropospheric Humidity* – vlhkost ve středních a horních hladinách troposféry; využití v NWP a klimatických modelech
- *Clear Sky Radiances* – celkové záření v bezoblačných oblastech

IASI (*Infrared Atmospheric Sounding Interferometer*) – je přístroj založen na bázi Michelsonova interferometru, obsahuje 8641 kanálů a měří IR záření ve spektrálním rozsahu $\lambda = 3,4 - 15,5 \mu m$. Primárně poskytuje informace o [30]:

- profilu teploty v troposféře a nižší stratosféře s přesností 1K a vertikálním rozlišením 1 km v nízké troposféře a horizontálním rozlišením 25 km
- profilu vodní páry v troposféře s přesností relativní vlhkosti 10% a vertikálním rozlišením 1 km v nízké troposféře a horizontálním rozlišením 25 km

MHS (*The Microwave Humidity Sounder*) – je 5 kanálový mikrovlnný radiometr, měří mikrovlnné záření emitované zemským povrchem ve specifických frekvenčních pásmech. Jelikož atmosférická vlhkost zeslabuje mikrovlnné záření emitované ze zemského povrchu, je možné určit detailní obraz vlhkosti s různými kanály odpovídající různým vertikálním hladinám. Frekvence kanálů jsou v rozsahu 89–190 GHz (kanály v rozsahu 157 – 183 GHz poskytují informace o vlhkosti) [30].

Každá anténa je tvořena ze 3 částí, které povolují simultánní pozorování ve 3 směrech. V kombinaci to poskytuje lepší rozlišení ve dvou snímaných pásmech o šířce 2×500 km [30]. Přístroj je umístěn na družicích NOAA 18 a MetOp A.

AMSU-A (*Advanced Microwave Sounding Units*) – Je 15 kanálový mikrovlnný radiometr, který v kombinaci s daty z přístroje HIRS slouží k získání profilů teploty a vlhkosti od zemského povrchu do horní stratosféry v hladinách po 48 km. Data jsou dále použita k měření srážek a vlastností povrchu (sněhové pokrývky, oceánských ledovců a půdní vlhkosti). Přístroj je umístěn na družicích NOAA 15 až 18, MetOp A, EOS a Aqua. [30].

AMSU-B (*Advanced Microwave Sounding Units*) – Je 5 kanálový mikrovlnný radiometr, který stejně jako AMSU-A slouží k získání profilů teploty a vlhkosti. Přístroj je umístěn na družicích NOAA 15 až 17 [30].

HIRS/4 (*High-resolution Infrared Sounder*) – je 20 kanálový IR radiometr, který v kombinaci s daty z AMSU slouží k výpočtu vertikálního teplotního profilu a

atmosférického tlaku od zemského povrchu do výšky asi 40 km. Přístroj je schopen měřit teplotu hladin oceánů, hodnot atmosférického ozónu, srážkové vody, výšky a pokrytí oblačnosti a albedo. Z výšky asi 800 km pokrývají jednotlivé kanály pás o šířce 1084 km a poskytují prostorové rozlišení zhruba 20 km v nadiru. Přístroj je umístěn na družicích NOAA 18, MetOp A [30].

AVHRR/3 (*Advanced Very High Resolution Radiometer*) – je 6 kanálový radiometr, který detekuje záření ve viditelné a IR části elektromagnetického spektra. Poskytuje snímky země, vody a oblaků s prostorovým rozlišením 1,1 km, pro okraj snímaného pásu území je rozlišení horší. Přístroj dále měří teplotu povrchu oceánů, led, sníh a vegetační pokrytí. Přístroj je umístěn na družicích NOAA 6 až 18 a MetOp A [30].

Přístroje MHS, AMSU-A, AMSU-B a HIRS je komplex přístrojů často označovaných ATOVS (*Advanced TIROS Operational Vertical Sounder*). Slouží k sledování zemské atmosféry a pracují ve spojení s přístrojem AVHRR. Celý komplex je umístěn na družici NOAA 18.

AIRS (*Atmospheric Infra-Red Sounder*) – spektrometr, který využívá 2378 kanálů k sondáži teploty a vlhkosti atmosféry, profilu ozónu a jiných plynů. Přístroj je umístěn na družicích EOS a Aqua [28].

ATMS (*Advanced Technology Microwave Sounder*) – je 22 kanálový mikrovlnný radiometr s rozlišením 16 km pro kanály 165 – 183 GHz, 32 km pro kanály 50 – 90 GHz, 75 km pro kanály 23 – 32 GHz. Poskytuje informace o teplotě a vlhkosti atmosféry. Přístroj je umístěn na družicích NPP, NPOESS 1/3 [28].

SSM/I (*Special Sensor Microwave/Imager*) – 7 kanálový mikrovlnný radiometr, operující ve 4 frekvencích a 2 polarizacích, získává informace o rychlosti větru na povrchu oceánů, vodní páře, množství vody v oblacích a množství srážek. Radiometr využívá 6 polárních družic DMSP společnosti the US Air Force. V současné době je radiometr SSM/I nahrazen (u družice DMSP-16) modernějším radiometrem SSMIS [31].

TMI (*TRMM Microwave Imager*) – 9 kanálový mikrovlnný radiometr, který funguje na 5 frekvencích nižších než u SSM/I. Je používán k získávání informací o teplotě zemského povrchu a rychlosti větru na hladině moří, vodní páře v atmosféře a množství srážek. Přístroj je umístěn na americké družici TRMM [31].

AMSR-E (*The Advanced Microwave Scanning Radiometer*) – je 12 kanálový mikrovlnný radiometr, pracující v 6 frekvencích, určený především k hydrologickým měřením. Je schopen získávat informace o teplotě na zemském povrchu, rychlosti větru, množství vodní páry v atmosféře, vody v oblacích a množství spadlých srážek. Radiometr byl vyvinutý japonskou organizací NASDA (*The National Space Development Agency*) a je umístěn na americké družici Aqua [31].

MODIS (*Moderate-resolution Imaging Spectro-radiometer*) – je 36 kanálový spektrometr, který snímá záření v širokém viditelném a infračerveném spektrálním rozhraní. Každý den poskytuje informace o změnách na zemském povrchu, oceánech a v atmosféře ve 3 prostorových rozlišeních: 250 m, 500 m a 1000 m. Pro asimilaci poskytuje informaci o větru v polárních oblastech. Přístroj je umístěn na palubě družic Terra a Aqua [32].

Aktivní družicové přístroje

GRAS (*The Global Navigation Satellite System Receiver for Atmospheric Sounding*) – je evropský GNSS přijímač, využívající RO technik, který funguje jako atmosférická sonda. Přístroj poskytuje každý den 500 profilů teploty s přesností $\pm 1\text{K}$ a s vertikálním rozlišením 150 m v troposféře (5 - 30 km) a rozlišením 1,5 km ve stratosféře. Je umístěn na družici MetOp A [30].

ASCAT (*Advanced Scatterometer*) – skaterometer určený k získávání informací o větru. Přístroj tvoří 2 antény, které vysílají na povrch oceánů elektromagnetické vlny a ty se zpětným rozptylem na rozvlhčené hladině vrací zpět do přijímače na družici. Ze získaných dat a vlastností zpětného rozptylu určí přístroj rychlost a směr větru [30].

QSCAT (označovaný jako skaterometer SeaWinds) – skaterometer vysílající vlny Ku-band (tedy při frekvencích blízko 14 GHz). Měří rychlost a směr větru poblíž hladiny oceánů a je také využíván v aplikacích týkajících se zemského povrchu a mořských ledovců. Je umístěn na palubě družice QuickSCAT, ADEOS-2, GCOM-W 2/3 a podobný přístroj je také na družici Midori II [31].

Tabulka 2.4: Přehled družicových přístrojů, využívaných v asimilaci dat

Přístroj	Družice
SEVIRI	Meteosat 8, 9
IASI	MetOp-A
MHS	NOAA-18, Metop-A
AMSU-A	NOAA-15 až 18, MetOp-A, Aqua
AMSU-B	NOAA-15/16/17
HIRS/4	TIROS-N, NOAA 6 až 18, Metop-A
AVHRR/3	TIROS-N, NOAA 6 až 18, MetOp-A
AIRS	Aqua
ATMS	NPP, NPOESS 1 až 4
SSM/I	DMSP F-8/10/11/13/14/15
TMI	TRMM
AMSR-E	Aqua
GRAS	MetOp-A
ASCAT	MetOp-A
QSCAT	QuickSCAT, GCOM-W 2/3
MODIS	Terra, Aqua

Kapitola 3

Využití meteorologických pozorování pro asimilaci dat

V předcházející kapitole byl uveden přehled meteorologických pozorování, která poskytují velké množství naměřených dat v různé kvalitě. Dříve než jsou naměřená data využita pro asimilaci, musí projít kontrolou kvality, která je nezbytným prvním krokem k získání kvalitní analýzy a následné předpovědi pomocí numerických předpovědních modelů.

Kontrola kvality meteorologických měření

Hlavní úloha kontroly kvality je detekce a vyloučení chybných nebo nepoužitelných pozorování, což je prakticky velmi složitá procedura, kterou v současné době obstarávají automatické systémy. Ty zahrnují následující kroky [2]:

- kontrola chyb kódování a hrubých chyb měření
- kontrola vzhledem k předběžnému poli
- kontrola prostorové a časové konzistence
- redukce pozorování

Základní kontrola zahrnuje kontroly chyb v kódování, příp. hrubých chyb měření z fyzikálního hlediska a kontroluje úplnost zprávy.

Následuje kontrola vzhledem k předběžnému poli, tj. kontrola srovnáním pozorovaných dat \mathbf{y} s jejich modelovými ekvivalenty $H(\mathbf{x})$. Pokud je rozdíl $\mathbf{y} - H(\mathbf{x})$ příliš velký, je toto měření vyřazeno. Je tedy zřejmé, že kontrola kvality závisí na přesnosti předběžného pole a může vyřadit i přesná měření, která se ovšem např. vlivem lokálních podmínek počasí (teplota v údolí, hřebeny hor aj.) liší od hodnot předběžného pole. To lze zdůvodnit tak, že předběžné pole neuvažuje lokální změny, a hodnota je nepoužitelná pro analýzu na daném rozlišení modelu [2].

Dalším krokem je kontrola prostorové (horizontální i vertikální) konzistence, která se provádí srovnáváním se sousedními hodnotami. Posledním krokem je redukce dat, která se aplikuje především na satelitní popř. letecká data a data z bojů. Tyto typy pozorování poskytují velké množství dat v čase, či v prostoru, a abychom se vyvarovali přetížení systému, zřetřující procedura automaticky data s velkou korelační chybou vyřadí. Dalším důležitou podmínkou pro pozorování je, že hodnoty nesmí být navzájem korelované, a tudíž splnění předpokladu diagonální matice chyb měření \mathbf{R} pro použití BLUE odhadu.

Družicová měření mohou být navíc zatížena systematickou chybou (tzv. biasem). Pokud se bias s časem nemění, bývá odstraněn jednoduše kalibrací přístroje (pomocí kalibračních schémat). Tyto s časem neměnné biasy závisí na technických okolnostech přístroje (vibrace při spouštění družice, sluneční bouře...) a jedná se o systematické chyby přístroje. Biasy se ovšem mohou s časem měnit a záviset na oblasti měření, podmínkách měření, aj. Všechny tyto systematické chyby je nutné odstranit dříve, než jsou použity v asimilaci.

Velký důraz se klade na neustálou kontrolu správnosti poskytnutých dat. Pokud data z některých typů pozorování vnášejí neustále chybu do analýzy, poté jsou zařazena na tzv. vyřazovací listinu (reject list, blacklist). Vyřazení chybných dat může být stálé nebo dočasné [24].

Využití dat pro asimilaci

Po vyřazení chybných nebo nepřesných měření kontrolou kvality, jsou data použita pro tvorbu analýzy metodami, které byly popsány v první kapitole. Využití jednotlivých typů měření pro asimilaci uvedu na příkladu asimilačního systému Evropského centra pro střednědobou předpověď (ECMWF, *The European Centre for Medium-Range Weather Forecasts*) viz [33], které operativně využívá metodu 4DVAR. V tabulce 3.1 viz [19] je přehled počtu dostupných dat a v tabulce 3.2 přehled počtu asimilovaných dat pro jedno 12h asimilační okno ze dne 24. dubna 2007.

V tabulkách jsou uvedena měření, se kterými jsme se seznámili v kapitole - typy pozorování. Pro stručné připomenutí některých z nich:

SYNOP – reprezentují měření z meteorologických stanic

Pilot – zahrnují měření PILOT (obsahují informace o větru z aerologických sondáží) a PROFILER (měření složek větru dálkovým snímáním, např. Dopplerovými radary)

AMV – je produktem geostacionárních družic, který poskytuje informace o směru a rychlosti větru, určená ze směru pohybu oblaků

Skaterometry – aktivní družicové přístroje, poskytující informace o větru blízko povrchu oceánů

GPS RO – jsou družicová aktivní měření užívající RO technik, která poskytují profily teploty a vlhkosti atmosféry

V tabulce 3.3 uvádíme přehled parametrů, které jsou pro daný typ pozorování v současné době asimilována [19].

Tabulka 3.1: Počet dostupných dat pro 12h asimilační interval (9-21 UTC) ze dne 24.dubna 2007, viz [19]

Měření	Dostupných dat	Podíl z celkového počtu dat [%]
SYNOP	421 000	0,43
Letecká	519 000	0,53
Bóje	24 000	0,02
Aerologická	152 000	0,16
Pilot	119 000	0,12
AMV	4 272 000	4,37
Radiance	91 786 000	93,91
Skaterometrická	274 000	0,28
GPS RO	167 000	0,17
Celkově	97 734 000	100

Tabulka 3.2: Počet asimilovaných dat pro 12h asimilační interval (9-21 UTC) ze dne 24.dubna 2007, viz [19]


Měření	Asimilovaných dat	Podíl z celkového počtu dat [%]
SYNOP	64 000	1,94
Letecká	247 000	7,53
Bóje	6 000	0,18
Aerologická	75 000	2,28
Pilot	57 000	1,75
AMV	131 000	3,99
Radiance	2 508 000	76,46
Skaterometrická	118 000	3,61
GPS RO	73 000	2,24
Celkově	3 280 000	100

Tabulka 3.3: Měřené veličiny pro konvenční pozorování

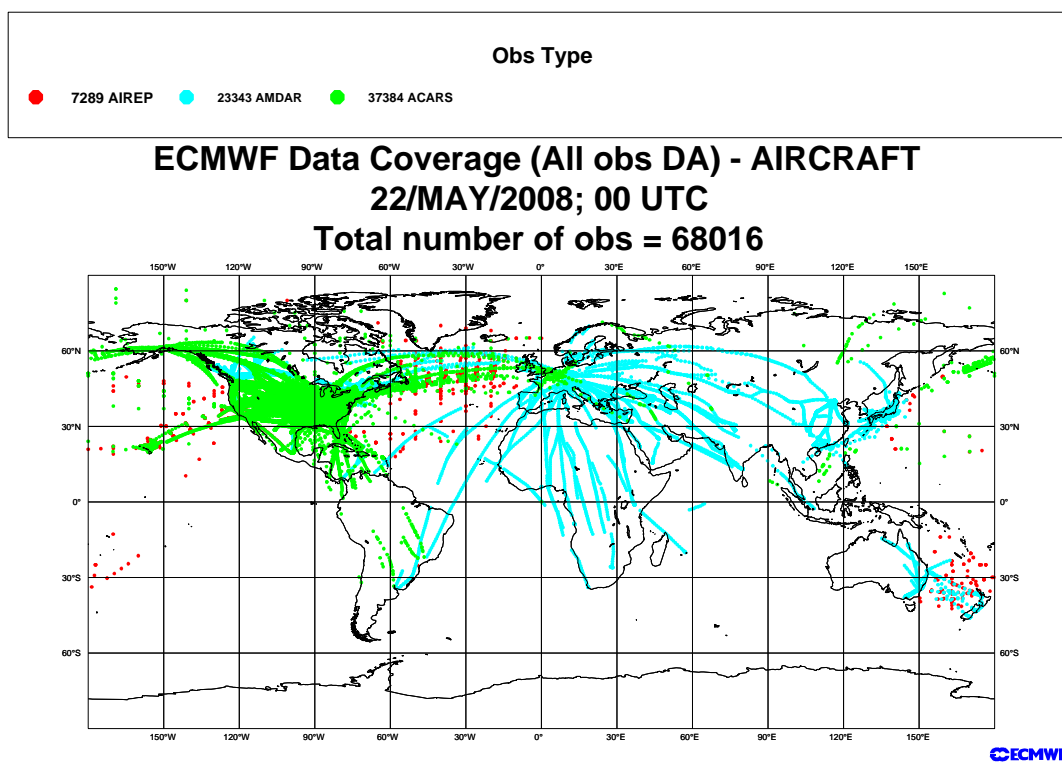
Typ pozorování	Měřené veličiny
SYNOP	tlak (na hladině moře), vítr (v 10m), rel. vlhkost (ve 2m)
Letecká	složky větru, teplota
Bóje	tlak (na hladině moře), vítr (v 10m)
Aerologická	vítr, teplota, relativní vlhkost
Pilot	složky větru
AMV	složky větru
Radiance	teplota (zemského povrchu, atmosféry), vlhkost
Skaterometry	složky větru
GPS RO	teplota a vlhkost

Z tabulek 3.1 a 3.2 je patrné, že 99% dostupných dat a 89% asimilovaných/užitých dat je původem z družic. Obrovský význam družicových dat pro předpověď počasí je dobře zřejmý v práci [18], kde můžeme vidět patrný rozdíl numerické předpovědi počasí pro severní a jižní polokouli pro případy, kdy družicová data použijeme či nikoli v asimilaci dat. Výsledkem je pokles úspěšné předpovědi na jižní polokouli pro 6 den zhruba o 20% v případě, že družicová data v asimilaci nepoužijeme. Na severní polokouli není tento rozdíl v důsledku dobrého pokrytí konvenčními měřeními až tak patrný.

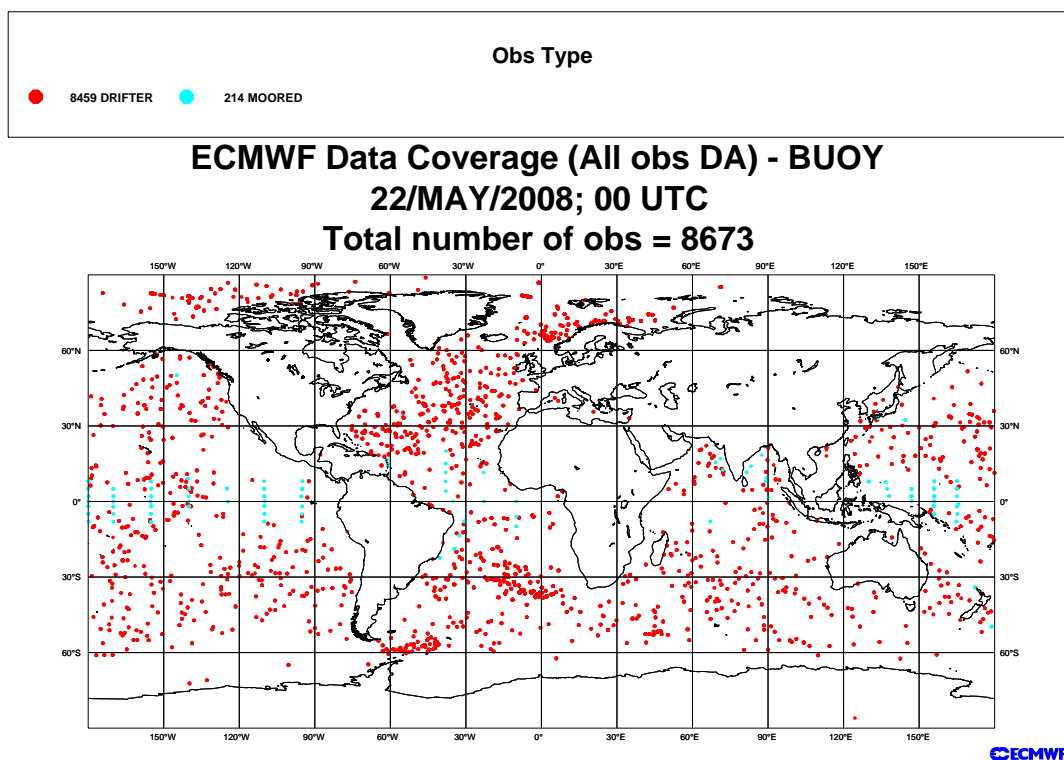
Prostorové pokrytí dostupných meteorologických měření, v čase 00 UTC z 21. května 2008, pro jednotlivé typy pozorování je patrné na obrázcích 3.1 až 3.11. Obrázky jsou převzaty ze stránek ECMWF viz [33].



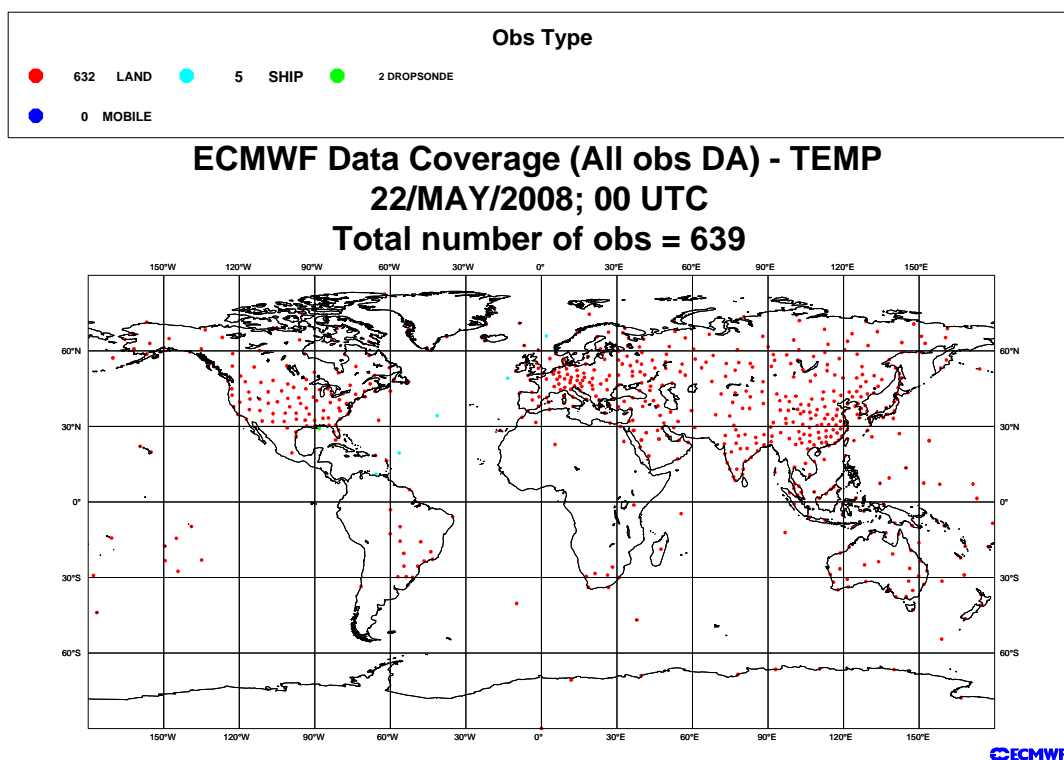
Obrázek 3.1: Pokrytí pozemních pozorování z meteorologických stanic a lodní.



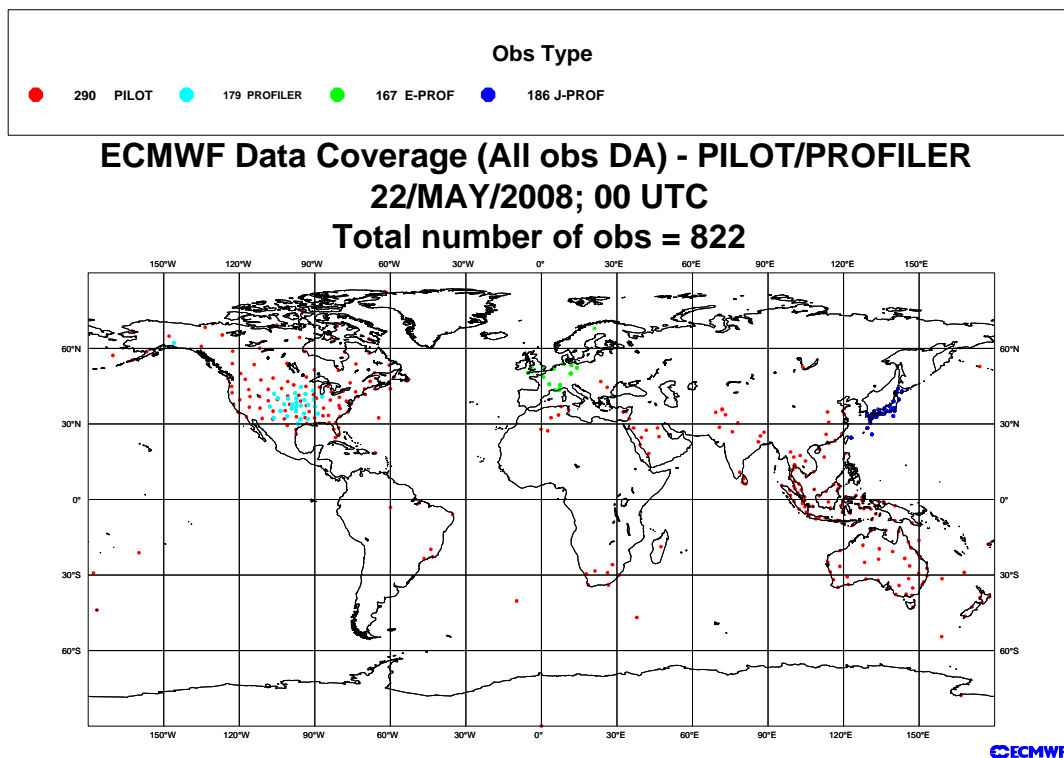
Obrázek 3.2: Pokrytí leteckých pozorování.



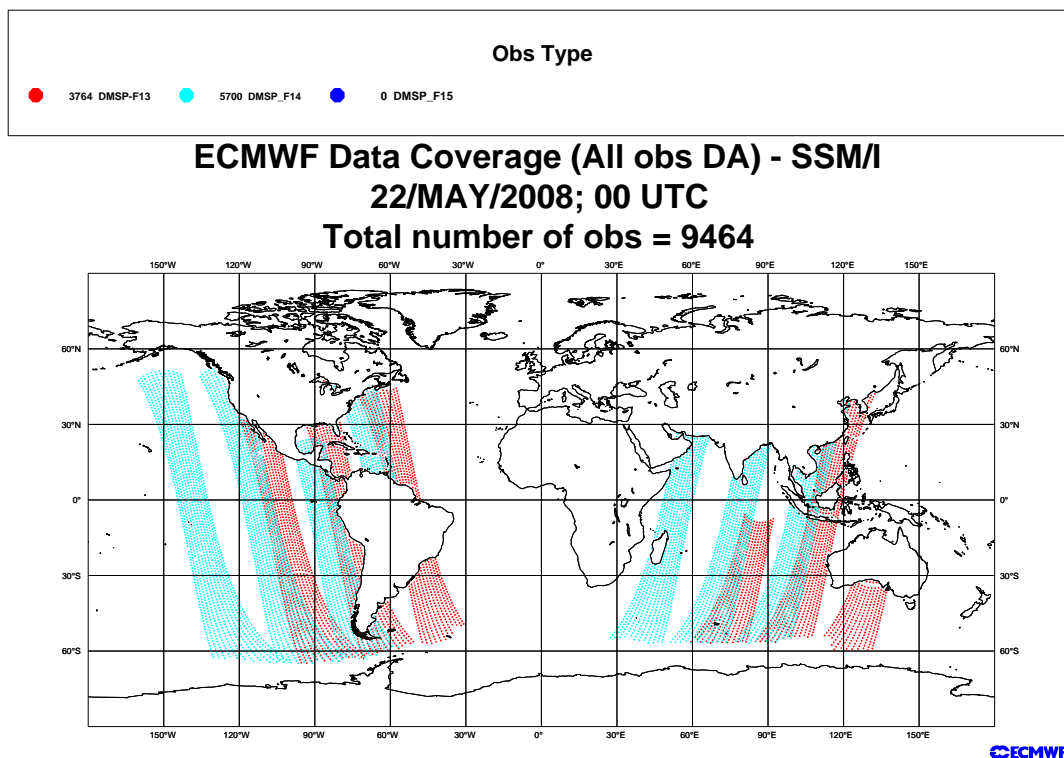
Obrázek 3.3: Pokrytí pozorování z meteorologických bójí na moři.



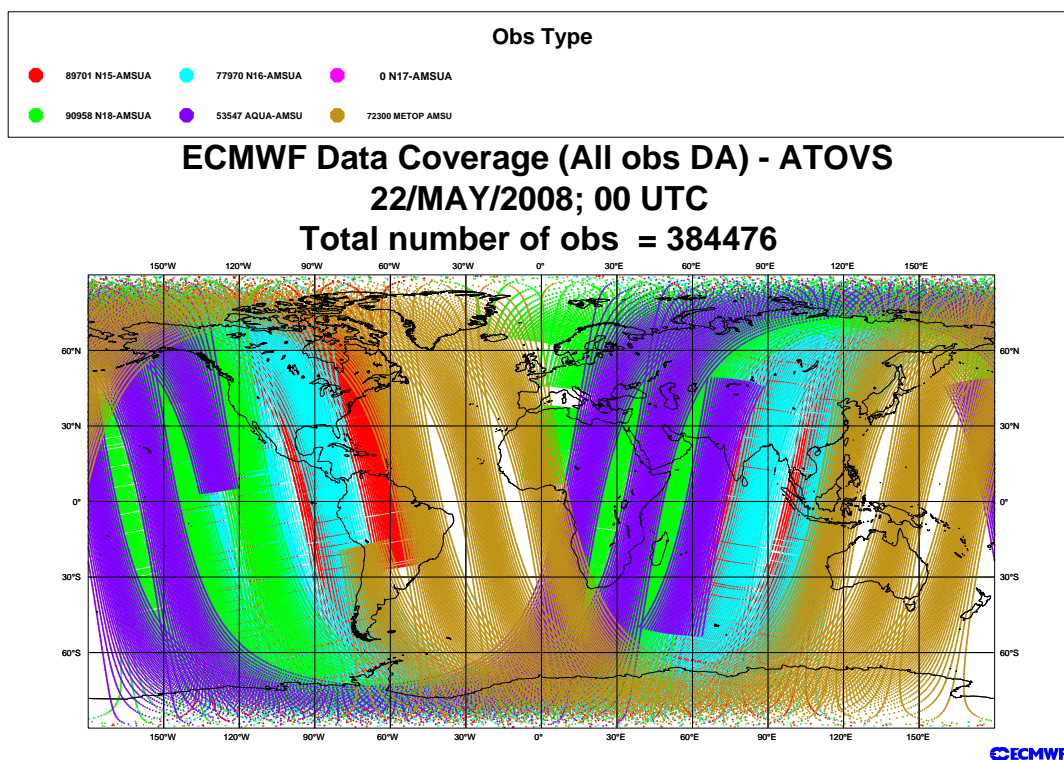
Obrázek 3.4: Pokrytí aerologických pozorování.



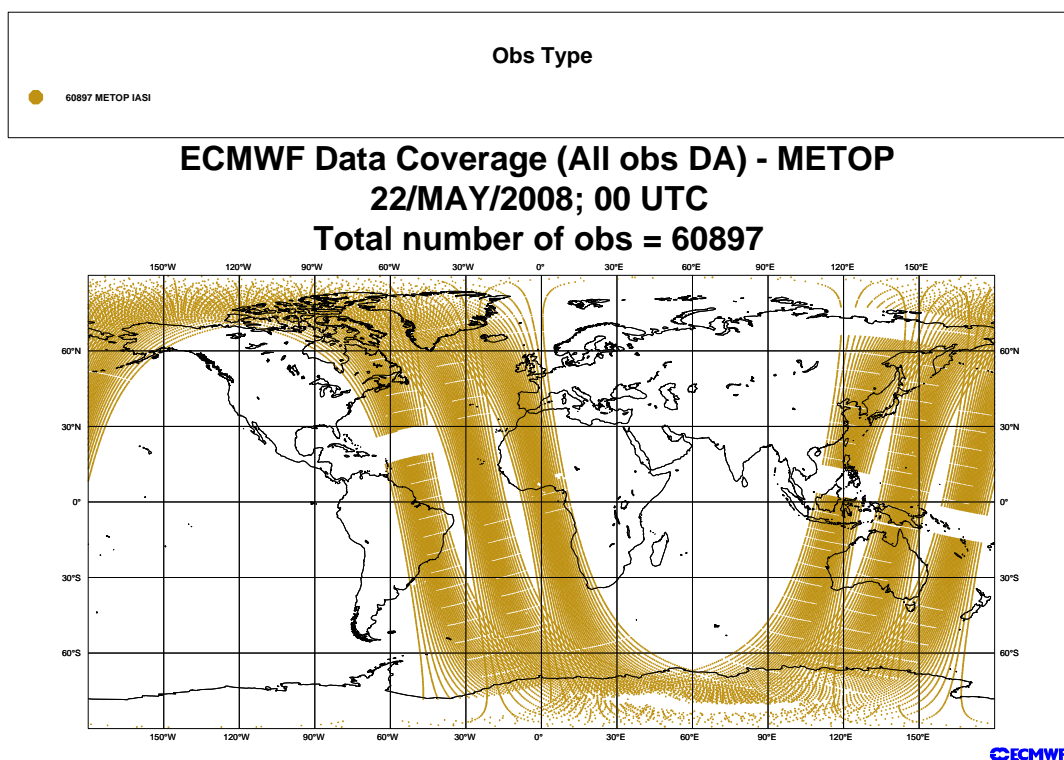
Obrázek 3.5: Pokrytí pozorování poskytující zprávu Pilot.




Obrázek 3.6: Pokrytí družicových měření přístrojem SSMI.



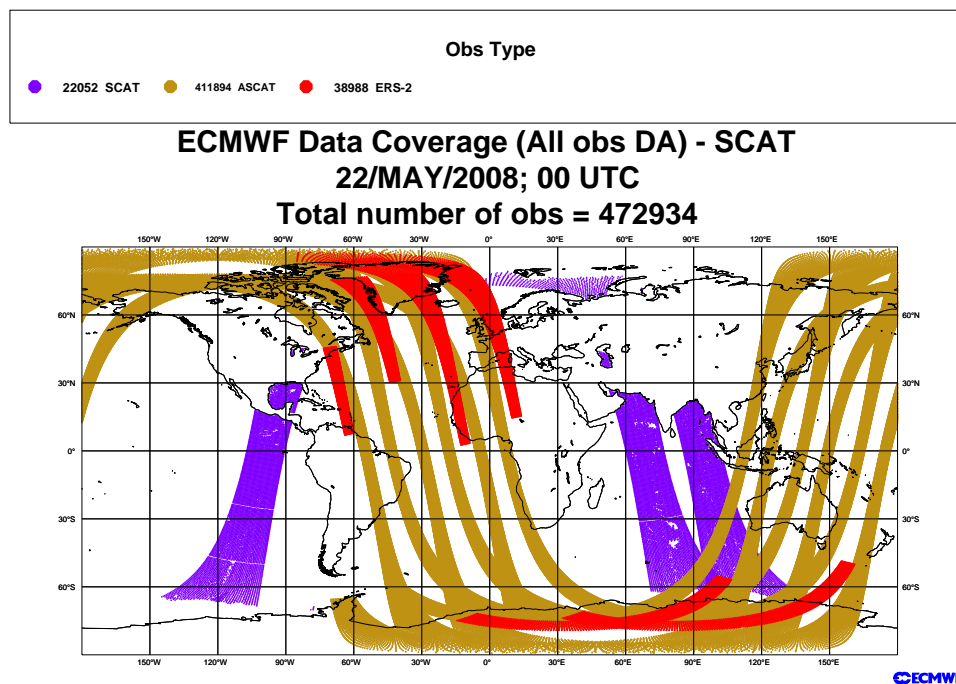
Obrázek 3.7: Pokrytí družicových měření přístroji ATOVS.



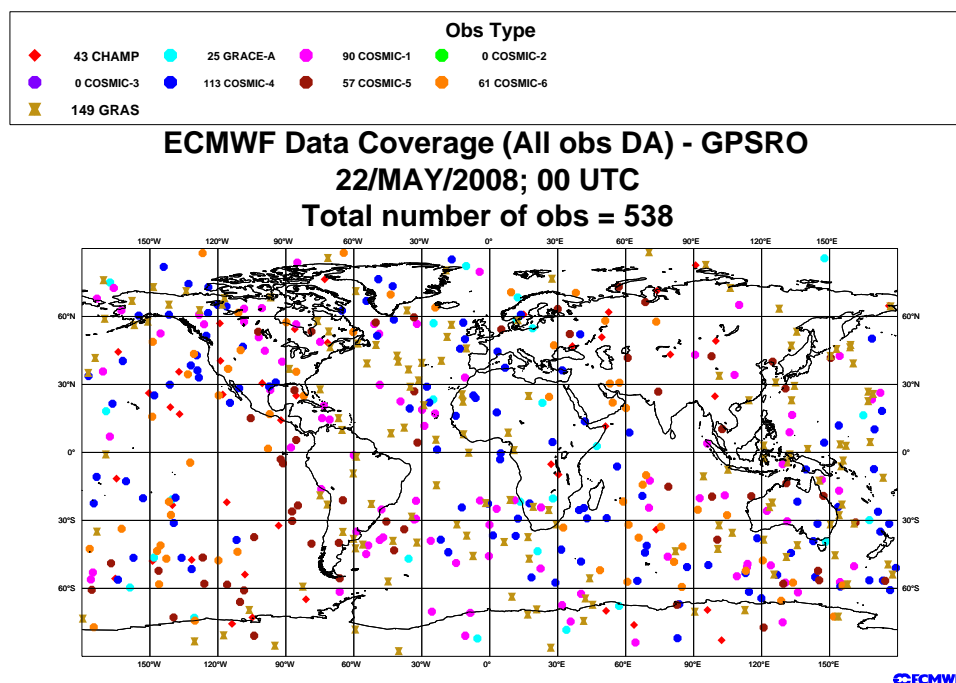
Obrázek 3.8: Pokrytí družicových měření družice MetOp-A.



Obrázek 3.9: Pokrytí měření vyzařování geostacionárními družicemi ve viditelném a IR spektru.



Obrázek 3.10: Pokrytí měření družicovými skaterometry.



Obrázek 3.11: Pokrytí měření družic, využívajících GPS RO technik.

Z obrázků 3.1 až 3.5 je patrné, že konvenční pozorování poskytují pouze velmi malé pokrytí meteorologických měření v oblasti moří a oceánů, kde převážná většina dat pochází z lodí, plošin a bójí. Z obrázků 3.6 až 3.11 je patrný obrovský význam družicového pozorování v těchto nedostupných oblastech.

Na obrázcích je také uveden počet dostupných pozorování, který se pro stanovené časy měření v 00, 06, 12, 18 UTC mění. Počet dostupných měření je vyšší především pro denní časy 06 a 12 UTC, a největší rozdíl v počtu dostupných dat mezi dnem a nocí je pro geostacionární družice. Ty měří v noci pouze v oblasti IR spektra a přes den poskytují data i ve viditelném spektru. Časovou dostupnost pro jednotlivé typy pozorování nalezneme na stránkách ECMWF viz [33].

Kapitola 4

Závěr

Cílem práce bylo seznámit se s některými metodami objektivní analýzy, které jsou v současné době využívány pro výpočet počáteční analýzy v numerických předpovědních modelech. V první kapitole jsme se seznámili s pojmem analýzy a asimilace dat, stručně popsali funkci asimilačního modelu a poté uvedli přehled metod objektivní analýzy. Seznámili jsme také se problémy modelování variačních matic chyb, které nám do analýzy s měřenými hodnotami a předběžným odhadem vstupují a zásadně ovlivňují kvalitu analýzy.

V druhé kapitole jsme se obeznámili s jednotlivými typy meteorologických pozorování z hlediska jejich využití v asimilaci dat. Podrobněji jsme se zmínili o družicovém pozorování, které v současné době představuje nejvýznamnější zdroj meteorologických dat, poskytujících informaci o stavu atmosféry, ve velmi dobrém prostorovém a časovém rozlišení.

V poslední kapitole jsme se seznámili s kontrolou kvality naměřených dat, která nám vybírá vhodná data, a určuje tak jejich kvantitativní využití a kvalitu výsledné analýzy. Aktuální využití dat pro asimilaci bylo demonstrováno na příkladu statistik asimilačního systému NWP modelu Evropského centra pro střednědobou předpověď počasí (ECMWF).

Literatura

- [1] Bouttier, F., Courtier, P. (2002): Data assimilation concepts and methods. Meteorological Training Course Lecture Series, ECMWF
- [2] Daley, R. (1991): Atmospheric Data Analysis. Cambridge University Press, 1991
- [3] ALATNET Seminar (2001): Optimal estimation in meteorology. Gourdon, 2001
- [4] Paniconi C., Marrocu M., Putti M., Verbunt M. (2003): Newtonian nudging for a Richards equation-based distributed hydrological model. Science direct, 2003
- [5] Auroux, D., Blum, J. (2007): A nudging-based data assimilation method: the Back and Forth Nudging (BFN) algorithm
- [6] Löscher A., Kirchengast G. (2008): Variational data assimilation for deriving global climate analyses from GNSS radio occultation data. Springer-Verlag, 2008
- [7] Vedel, H., Sattler, K. (2002): TOUGH (Targenting Optimal Use of GPS Humidity Measurements in Meteorology. Danish Meteorological Institute, 2002
- [8] Anděl, J. (2005): Základy matematické statistiky. Matfyzpress, Praha, 2005
- [9] Ministerstvo životního prostředí (1993): Meteorologický slovník výkladový a terminologický. Academia, Praha, 1993
- [10] Thépaut, J., Andersson, E. (2003): Assimilation of high-resolution satellite data *ECMWF Newsletter*, **No. 97**,
- [11] Brožková, R. (2007): Asimilace dat II, L8, ČHMÚ
- [12] Navon, M. (D): ata assimilation for Numerical Weather Prediction: a review. Pdf formát
- [13] Sokol, Z., Řezáčová D. (2006): Asimilace radarové odrazivosti do numerického modelu předpovědi počasí s vysokým rozlišením *Meteorologické zprávy*, **ročník 59, číslo 1**,
- [14] Brožková, R. (2005): Asimilace dat *Meteorologické zprávy*, **ročník 58, číslo 1**,

-
- [15] Persson, A., Grazzini, F. (2007): User Guide to ECMWF forecast products. ECMWF, Version 4.0
http://www.ecmwf.int/products/forecasts/guide/General_overview.html
- [16] Setvák, M. (2004): MSG - Meteosat druhé generace, ČHMÚ - družicové oddělení
http://www.chmi.cz/meteo/sat/setvak/pub/MetZpravy-2004_Setvak-MSG.pdf
- [17] Bydžovská M. *Systém meteorologických družic, data a využití*, ročníková práce, PřF UK, 2004, pdf formát
- [18] McNally, T. (2007): The Analysis of Satellite Data, Lekce 1
http://www.ecmwf.int/newsevents/training/meteorological_presentations/pdf/DA/SatAn1.pdf
- [19] Isaksen, L. (2007): The Operational Data Assimilation System
http://www.ecmwf.int/newsevents/training/meteorological_presentations/MET_DA.html
- [20] Benedetti, A. (2007): Tangent Linear and Adjoint
http://www.ecmwf.int/newsevents/training/meteorological_presentations/MET_DA.html
- [21] GOS – Global Observing System
<http://www.wmo.ch/pages/prog/www/OSY/gos-components.html>
- [22] ČHMÚ – oddělení aerologických přízemních pozorování
http://www.chmi.cz/meteo/oap/oap_basic.html
- [23] ČHMÚ – družicové oddělení
<http://www.chmi.cz/meteo/sat/>
- [24] Met Office
<http://www.metoffice.gov.uk/research/>
- [25] RTTOV – Radiative Transfer for TOVS
http://www.metoffice.gov.uk/research/interproj/nwpsaf/rtm/rttov8_description.html
- [26] GFZ Postdam
<http://www.cosmic.ucar.edu/>
- [27] GISAT
<http://www.gisat.cz/>
- [28] WMO – World Meteorological Organization
<http://www.wmo.int/>

-
- [29] NOAA – National Oceanic and Atmospheric Administration
<http://www.noaa.gov/>
- [30] ESA – European Space Agency (družice MetOp)
<http://www.esa.int/esaLP/LPmetop.html>
- [31] Remote Sensing Systems
<http://www.ssmi.com/>
- [32] MODIS – MODerate resolution Imaging Spectrometer
<http://modis.gsfc.nasa.gov/data/>
- [33] ECMWF – European Centre for Medium-Range Weather Forecasts
<http://www.ecmwf.int>
- [34] ČHMÚ – oddělení radarových měření
<http://www.chmi.cz/meteo/rad/>