

Vpliv metod za odstranitev pegastega šuma na oceno vlažnosti iz slik SAR

Matej Kseneman, Dušan Gleich, Peter Planinšič, Žarko Čučej

Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova 17, 2000 Maribor, Slovenija

E-pošta: matej.kseneman@gmail.com, dusan.gleich@uni-mb.si

Povzetek. V članku opisujemo vpliv metod za odstranjevanje pegastega šuma z radarskih posnetkov z umetno odprtino (SAR) na oceno vlažnosti iz dualno polariziranih slik. Raziskali smo tri metode odpravljanja pegastega šuma, ki temeljijo na maksimizaciji gostote verjetnosti posteriorja. Prvi dve metodi delujeta v slikovnem prostoru in za gostoto verjetnosti apriorja uporabljata Gauss-Markova naključna polja (GMRF) in avtobinomski model (ABM). V obeh primerih smo za oceno šuma v posnetku uporabili Bayesovo sklepanje prvega reda, za ocenitev najboljšega modela pa Bayesovo sklepanje drugega reda. Tretja metoda deluje v valčnem prostoru. Za oceno apriorja smo uporabili Gauss-Markovo naključno polje v valčnem prostoru, za verjetje pa Gaussovo gostoto verjetnosti. Cilj odstranjevanja pegastega šuma je izločiti pegasti šum s posnetkov s SAR tako, da se ohranijo bistvene lastnosti slike, kot so robovi, teksture, sence itd. Vlažnost ocenjujemo z Duboisovim modelom. Poskusni rezultati so pokazali, da vse metode zmanjševanja pegastega šuma dajo približno enake rezultate, vendar dajemo prednost modelu GMRF v valčnem prostoru, saj deluje najhitreje.

Ključne besede: radar z umetno odprtino (SAR), ocenjevanje parametrov, Bayesov izrek, ocenjevanje vlažnosti

The impact of despeckling methods on soil-moisture estimation using SAR data

Extended abstract. The paper deals with the impact of synthetic-aperture radar (SAR) image despeckling on soil moisture estimation. X-band data are used. We investigated the correlation of the X-band SAR data for soil moisture estimation. Three model-based methods for SAR image despeckling using the Bayesian approach are presented. The Bayes theorem and the maximization of the posterior are given in (1) and (2), respectively. The likelihood pdf is provided with the Gamma pdf in (3). The GMRF and auto-binomial models are defined using (4) and (5), respectively. A maximum a-posteriori estimate (MAP) of the GMRF and ABM models are defined in (6)-(7). The evidence maximization technique is presented for the GMRF and ABM priors using (11) and (12). Section 2.1 presents the wavelet-based despeckling using the Generalized Gauss-Markov (GGMRF) prior. The computation of the speckle variance in the wavelet domain is presented using (13). The GGMRF prior is defined in (14) and the speckle pdf or likelihood is assumed as a Gaussian pdf (15). The MAP estimate in the wavelet domain is defined in (16) together with an estimation of the texture parameters using the minimum mean square-error model. Section 3 presents a semi empirical model (17) for estimation of the dielectric constant and the roughness (18) of the terrain using the Dubois model. The experimental results in Table 1 show that all the presented methods work well using the synthetic data. The wavelet-based method is the fastest among the proposed methods and gives very good results using the synthetic data, as shown in Fig. 1a-1f. The real SAR image is shown in Fig. 2a. The despeckled real SAR images using MAP-GMRF, MAP-ABM and WGEM and LUWD [1] methods are shown in Figs. 2c-2f. A comparison of the estimated soil

moisture using different despeckling methods and measured soil moisture is shown in Fig. 3. The experimental results showed that any of the presented despeckling methods can be used for despeckling of the polarized data and the estimated values of the soil moisture can be compared.

Key words: Synthetic-Aperture Radar (SAR), despeckling, Bayes theorem, soil-moisture estimation

1 Uvod

Radarji s sintetično odprtino (ang. Synthetic Aperture Radar) ali na kratko SAR so radarski sistemi, ki delujejo v vseh vremenskih razmerah, podnevi in ponoči. Sistemi SAR, ki jih bomo uporabljali v tem prispevku so namenjeni opazovanju površine Zemlje in so nameščeni na satelitskih platformah. Uporabljajo se tudi sistemi SAR, ki so nameščeni na letalih. V tem prispevku se bomo omejili na radar bočnega razgleda, ki je aktivni instrument in deluje s frekvenco 9,65 GHz (3,2 cm, pas X). Radar uporablja Dopplerjev pojav in uporablja obdelavo signalov za doseganje visoke ločljivosti. Leta 2007 je Nemška vesoljska agencija (DLR) izstrelila satelit TerraSAR-X, ki dosega resolucijo enega metra. Prav tako je bil v istem letu izstreljen sistem satelitov COSMO-

SkyMed, ki bo sistem štirih satelitov. V letu 2010 je DLR izatrelil tudi drugi satelit Tandem-X, ki deluje v tandemu z obstoječim satelitom TerraSAR-X in zagotavlja podatke SAR namenjene interferometriji. Slike SAR vsebujejo pegasti šum (ang. speckle), ki prekriva informacije o sceni in otežuje avtomatsko analizo slik SAR. Pegasti šum je posledica sipanja elektromagnetnega valovanja in interferenc odbitih elektromagnetnih valov. V zadnjih dveh desetletjih je bilo razvitih veliko metod za odstranjevanje pegastega šuma. Najbolj znane metode za odstranjevanje pegastega šuma so filter Lee, izboljšani filter Lee, Gamma-MAP, Kuan in filtri Frost, ki so bili razviti v devetdesetih letih prejšnjega stoletja. Moderne metode odpravljanja pegastega šuma uporabljajo Bayesov izrek, ki s pomočjo maksimiranja posteriorne gostote verjetnosti določi cenilko maksimalne posteriorne gostote verjetnosti (MAP). V ta namen moramo poznati gostoto verjetnosti verjetja (ang. likelihood), apriorno gostoto verjetnosti (ang. prior) in gostoto verjetnosti izračuna (ang. evidence) [2]. Verjetje, ki modelira pegasti šum, ima gama porazdelitev, sliko pa lahko modeliramo s porazdelitvijo gama, Gauss-Markovimi naključnimi polji (GMRF), posplošeno Gaussovo porazdelitvijo itd. Kadar uporabimo GMRF, moramo oceniti tudi parameter teksture, ki ga ta omogoča. Za oceno najboljših parametrov, ki se prilegajo originalni sliki, uporabljamo funkcijo maksimalnega izračuna ali Bayesovo odločanje drugega reda. V zadnjih letih se je zelo uveljavila valčna (ang. wavelet) transformacija za odpravo pegastega šuma iz slik SAR. Podobni postopki kot v slikovnem prostoru se lahko uporabijo tudi v frekvenčnem prostoru, vendar moramo pravilno modelirati sliko SAR in pegasti šum. Sliko SAR lahko modeliramo s posplošenimi Gauss-Markovimi naključnimi polji in pegasti šum kakor Gaussovo porazdelitev. Cenilko MAP in maksimizacijo gostote verjetnosti izračuna v valčnem prostoru [3] smo predstavili v [4] in izboljšano varianto algoritma z uporabo maksimizacije pričakovane vrednosti v [5]. Med napredne metode za odstranjevanje pegastega šuma pa štejemo metodo, ki smo jo razvili v sodelovanju z nemško vesoljsko agencijo (DLR), ki odstranjuje pegasti šum v kompleksnem prostoru [6]. Prispevek predstavlja vpliv postopkov odpravljanja pegastega šuma na oceno vlažnosti iz slik SAR. V ta namen smo izbrali model Duobis, ki spada med empirične modele, za svoje delovanje pa potrebuje polarizirano sliko SAR v horizontalni in vertikalni smeri. Model Duobis potrebuje za svoje delovanje normirano varianco σ^0 , ki jo dobimo iz detekcije kompleksnih podatkov. Glavni problem, na katerega naletimo pri ocenjevanju vlažnosti, je pegasti šum, ki zelo razprši ocenitev vlažnosti. Zato smo se odločili, da predstavimo metode za odpravo pegastega šuma, rezultate meritev vlažnosti s kapacitivno sondo in rezultate ocene vlažnosti iz slik SAR s tremi metodami odstranjevanje pegastega šuma, in sicer z avtobinomskim modelom (ABM), Gauss-Markovim modelom in metodo,

ki deluje v valčnem prostoru in uporablja model GMRF.

2 Odpravljanje šuma iz slik SAR

Modeliranje slik SAR v slikovnem prostoru z uporabo Gauss-Markovih naključnih polj je predstavil M. Walessa v [7]. Predstavil je idejo za ocenjevanje brezšumnih slik SAR z maksimizacijo posteriorja (ang. Maximum a Posterior) ali cenilko MAP ter poiskal parametre teksture GMRF s pomočjo maksimizacije gostote verjetnostnega izračuna. Bayesov izrek je dan z

$$p(\mathbf{x}|\mathbf{y}, \theta) = \frac{p(\mathbf{y}|\mathbf{x}, \theta)p(\mathbf{x}|\theta)}{p(\mathbf{y}|\theta)}, \quad (1)$$

kjer \mathbf{x} pomeni brezšumno sliko, \mathbf{y} šumno sliko, $p(\mathbf{x}|\mathbf{y}, \theta)$ verjetnostno funkcijo *posteriorja*, $p(\mathbf{y}|\mathbf{x}, \theta)$ verjetnostno funkcijo *verjetja*, verjetnostno funkcijo *apriorja* $p(\mathbf{x}|\theta)$, $p(\mathbf{y}|\theta)$ verjetnostno funkcijo izračuna. Za ocenitev brezšumne slike iz šumne se izraz (1) maksimira glede na spremenljivko x , pri tem je cenilka maksimalnega posteriorja (MAP) dana z

$$\hat{\mathbf{x}}(\mathbf{y}) = \arg \max_{\mathbf{x}} p(\mathbf{y}|\mathbf{x}, \theta)p(\mathbf{x}|\theta). \quad (2)$$

V (2) lahko zapišemo enačaj, ker verjetnostna funkcija izračuna $p(y)$ ne igra vloge pri maksimizaciji posteriorne verjetnostne funkcije. Za izpeljavo cenilke MAP moramo definirati verjetnostni funkciji verjetja in apriorja, ki predstavljata model pegastega šuma in model slike. Pegasti šum v amplitudni sliki SAR je dobro opisan s porazdelitvijo gama, ki je dana z

$$p(y_s|x_s) = 2 \left(\frac{y_s}{x_s} \right)^{(2L-1)} \frac{L^L}{x_s \Gamma(L)} e^{-L(y_s/x_s)^2}, \quad (3)$$

kjer je L število pogledov, ki je enako razmerju med kvadratom srednje vrednosti in varianco $L \approx \frac{\mu_s^2}{\sigma^2}$. Število pogledov L si lahko razlagamo kot mero velikosti prisotnega šuma. Originalna amplitudna slika, detektirana iz kompleksnih podatkov, ima en pogled. Če vzamemo dva posnetka in ju povprečimo, dobimo dva pogleda, itd. Z večanjem števila pogledov se zmanjšuje prisotnost šuma v sliki SAR. Sliko SAR lahko modeliramo z Gauss-Markovim naključnim poljem (GMRF), kjer je apriorna gostota verjetnosti enaka

$$p(x_s|\theta) = \frac{1}{\sqrt{2\pi\sigma_x^2}} \exp -\frac{(x_s - \mu_s)^2}{2\sigma_x^2}, \quad (4)$$

kjer je σ_x^2 varianca signala brez šuma in $\mu_s = \sum_{r \in N_s} \theta_r (x_{s+r} + x_{s-r})$. x_s je ocenjen element slike na lokaciji $s \in \{i, j\}$. Slika je definirana kakor dvodimenzionalno polje z indeksoma $0 \leq i < H$ in $0 \leq j < W$ ter horizontalno in vertikalno dimenzijo W, H . Spremenljivka N_s definira kliko

oz. soseščino okrog opazovane točke v sliki, izraz $\sum_{r \in N_s} \theta_r(x_{s+r} + x_{s-r})$ pa pomeni vsoto sosednjih točk v sliki. Za model prvega reda Markovega naključnega polja (MRF) se izvede vsota s horizontalnimi in vertikalnimi točkami v sliki, ki ležijo okrog opazovane točke v sliki. Nabor sosednjih točk v sliki je definiran kot $N_s = \{(0, 1), (0, -1), (1, 0), (-1, 0)\}$ in za model drugega reda kot $N_s = \{(0, 1), (0, -1), (1, 0), (-1, 0), (1, 1), (-1, -1), (1, -1), (-1, 1)\}$. Model MRF je definiran za simetrične množice sosedov, kar lahko zapišemo kot $r \in N_s$, potem $-r \notin N_s$ in N je definiran kot $N = (r : r \in N_s) \cup (-r : r \in N_s)$.

Sliko SAR lahko tudi modeliramo z avtobinomskim modelom (ABM) [8]

$$p(x_s | \theta) = \binom{G}{x_s} \rho_s^{x_s} (1 - \rho_s)^{G - x_s}, \rho_s = \frac{1}{(1 + \exp(-\zeta_s))}$$

$$\zeta_s = a_s + \sum_{r \in N_s} b_r (x_{s+r} + x_{s-r}) \quad (5)$$

Parametri teksture ABM so definirani z izrazom $\theta = [a, b_{11}, b_{12}, b_{21}, b_{22}, \dots]$, kjer za parameter a velja $a = -\sum_{i,j} b_{ij}$. Cenilko MAP dobimo, če maksimiramo produkt apriorja in verjetja. Če maksimiramo produkt apriorja (4) in verjetja (3) dobimo cenilko MAP-GMRF

$$x_s^4 - \mu_s x_s^3 + 2L \sigma_x^2 x_s^2 - 2L \sigma_x^2 y_s^2 = 0. \quad (6)$$

Podobno dobimo za cenilko MAP-ABM

$$-\frac{2L}{x_s} + 2L \frac{y_s^2}{x_s^3} + \log \frac{G - x_s}{x_s + 1} + \log \frac{\rho_s}{1 - \rho_s} = 0. \quad (7)$$

Cenilka MAP (7) se izračuna z numerično metodo, medtem ko ima cenilka MAP-GMRF (6) analitično rešitev. Parameter θ definira parametre teksture v modelih ABM in GMRF. Parameter θ definira teksturni model GMRF in ABM in ga moramo določiti s t. i. proceduro maksimiranja verjetnostne funkcije izračuna. Verjetnostne funkcije izračuna $p(\mathbf{y}|\mathbf{x}) = \int p(\mathbf{y}|\mathbf{x})p(\mathbf{x}|\theta)d\mathbf{x}$ ne moremo izračunati analitično, zato integral izračunamo z uporabo Hessejevega približka

$$p(\mathbf{y}|\theta) \approx \frac{(2\pi)^{N/2}}{\sqrt{|\mathbf{H}|}} \prod_{i=1}^N p(y_i|x_i)p(x_i|\theta), \quad (8)$$

kjer je $\Delta \mathbf{x} = (\mathbf{x} - \hat{\mathbf{x}})$ in je \mathbf{H} Hessiana matrika podana z

$$\mathbf{H} = -\nabla \nabla \sum_{i=1}^N \log(p(y_i|x_i)p(x_i|\theta)). \quad (9)$$

Z uporabo logaritmiranja lahko izraz (8) poenostavimo kot

$$\log p(\mathbf{y}|\theta) \approx \sum_{i=1}^N \frac{1}{2} (\log 2\pi - \log h_{ii}) + \log p(y_i|\hat{x}_i) + \log p(\hat{x}_i|\theta), \quad (10)$$

kjer so h_{ii} diagonalni elementi matrike \mathbf{H} in N pomeni število točk v oknu. Matriko \mathbf{H} lahko zapišemo kot $|\mathbf{H}| \approx \prod_{i=1}^N h_{ii}$. Če uporabimo model GMRF (4) in funkcijo verjetja gama (3), dobimo

$$h_{ii} = \frac{6Ly_s^2}{x_{s_{GMRF}}^2} - \frac{2L}{x_{s_{GMRF}}^2} + \frac{1}{\sigma_x} (1 + |\theta|^2), \quad (11)$$

kjer je $x_{s_{GMRF}}$ MAP-GMRF cenilka, izračunana s (6). Za aprior ABM (5) in porazdelitveno funkcijo gama (3) dobimo

$$h_{ii} = \frac{6Ly_s^2}{x_{s_{ABM}}^2} - \frac{2L}{x_{s_{ABM}}^2} + \frac{1}{G-1} - \frac{1}{x_{s_{ABM}} + 1}, \quad (12)$$

kjer je $x_{s_{ABM}}$ cenilka MAP-ABM izračunana s (6). Za izvedbo algoritma potrebujemo dve okni. V prvem oknu velikosti $N \times N$ ocenjujemo parametre teksture s premikanjem drugega okna velikosti $M \times M$, ki je ponavlja manjše ali enako prvemu. V oknu velikosti $N \times N$ izračunavamo vrednosti verjetnosti izračuna (10) za vsak parameter θ in ga spreminjamo tako dolgo, da dosežemo maksimalno vrednost (10). Parameter θ ima začetno vrednost $\theta = [0, 125, 0, 125, 0, 125, 0, 125]$, kadar uporabimo model drugega reda. Za ta parameter izračunamo cenilko MAP (6) in začetno vrednost verjetnosti izračuna (10). Nato spremenimo prvi parameter θ_0 za 0,1 in izračunamo (10). Če se je vrednost (10) povečala, to pomeni, da se spremenjen parameter bolje prilega podatkom kot prejšnji, zato ga v naslednjem koraku povečamo v isto smer. Nato za 0,1 povečamo še drugi parameter θ_1 in sklepamo enako. Če se vrednost verjetnosti izračuna zmanjša, spreminjamo trenutni parameter v nasprotni smeri. Parameter spreminjamo tako dolgo, da ni več spremembe v vrednosti izraza (10), in takrat predvidevamo, da smo dosegli maksimum (10). Dobljeni parametri so parametri teksture točk v sliki, ki jih omejuje majhno okno v velikosti $M \times M$. Cenilke MAP za izračunani parameter θ vpišemo prav tako v okno velikosti $M \times M$. Algoritem se pomakne za M točk in ponovno izračuna cenilko MAP in parameter teksture, dokler ne doseže konca slike.

2.1 Modeliranje slike SAR v valčnem prostoru z GGMRF

Modeliranje slik SAR v valčnem prostoru smo predstavili v [4] in [5]. Gre za uporabo Bayesove teorije v valčnem prostoru, kjer smo uporabili posplošen Gauss-Markov model za modeliranje slike v valčnem prostoru. Pegasti šum smo modelirali z Gaussovo gostoto verjetnosti. Uporabili smo modele pegastega šuma v valčnem prostoru, kakor je predlagano [1]. Varianco šuma v valčnem prostoru lahko ocenimo z $\sigma_n^2 = \psi_j \mu_x^2 C_F^2 (1 + C_x^2)$, kjer je $\mu_x = E[x]$ in $E[x]$ matematično upanje. C_x^2 je definiran $C_x^2 = \frac{C_{W_y}^2 - \psi_l C_F^2}{\psi_l (1 + C_F^2)}$. Normalizirano standardno deviacijo šumnih valčnih koeficientov definiramo

kot $C_{Wy} = \frac{\sigma_{Wy}}{\mu_y}$, kjer je σ_{Wy} standardna deviacija, izračunana v valčnem prostoru, in μ_y je srednja vrednost, izračunana v slikovnem prostoru. σ_{Wy} je izračunana v oknu 3×3 v valčnem prostoru in μ_y izračunana nad pripadajočimi koeficienti v originalnem prostoru (okno 3×3 v valčnem prostoru ustreza oknu pri najvišji frekvenci 6×6 v slikovnem prostoru). V izrazu za kovarianco C_x^2 , C_F pomeni normalizirano standardno deviacijo pegastega šuma. Pegasti šum je naključna spremenljivka \mathbf{z} ($E[\mathbf{z}] = 1$) in C_F je enak $1/\sqrt{L}$ za intenzivnostne slike in $C_F = \sqrt{(4/\pi - 1)/L}$ za amplitudne slike. Parameter ψ_l je definiran kot produkt visokofrekvenčnega g_k in nizkofrekvenčnega h_k dela filtrske banke uporabljene pri konstrukciji l -tega nivoja valčne razstavitve $\psi_j = (\sum_k h_k^2)^2 (\sum_k k_k^2)^{2(j-1)}$. $E[y]$ je enaka $E[x]$, ker je pegasti šum normaliziran. Varianco šuma zapišemo kot

$$\sigma_n^2 = \frac{C_F^2(\psi_j \mu_y^2 + \sigma_{Wy}^2)}{1 + C_F^2}, \quad (13)$$

kjer je $\mu_y = E[y]$. V valčnem prostoru sliko modeliramo z verjetnostno funkcijo posplošenega Gauss-Markovega naključnega polja

$$p(x_i|\theta) = \frac{\nu \eta(\nu, \sigma_x)}{2\Gamma(1/\nu)} e^{(-[\eta(\nu, \sigma_x)|A|]^\nu)}, \quad (14)$$

kjer so ν faktor oblike, σ_x standardna deviacija, $\Gamma(\cdot)$ Gamma funkcija, x_s valčni brezšumni koeficient, y_s šumni valčni koeficient, $\eta(\nu, \sigma_x) = \sigma_x^{-1} \sqrt{\frac{\Gamma(3/\nu)}{\Gamma(1/\nu)}}$ in $A = x_i - \sum_{j \in \zeta} \theta_j (x_i^j + x_i^j)$. Pegasti šum je multiplikativni šum. Pogosto uporabimo logaritemsko funkcijo, da prevedemo multiplikativni šum v aditivnega. Uporabili smo signalno odvisen aditivni model in porazdelitveno funkcijo verjetja zapisali kot

$$p(y_i|x_i) = \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{(y_i - x_i)^2}{2\sigma_n^2}\right). \quad (15)$$

Cenilko MAP poiščemo s pomočjo (2) in dobimo

$$-\nu \eta(\nu, \sigma_x) [\eta(\nu, \sigma_x)|A|]^{\nu-1} + \frac{y_i - x_i}{\sigma_n^2} = 0. \quad (16)$$

Spremenljivka ν se spreminja znotraj intervala $[0, 8, 2, 0]$ po korakih 0,2. Algoritem izračunava vrednosti cenilke MAP v valčnem prostoru in za vsako vrednost ν izračuna parametre teksture s cenilko najmanjšega srednjega kvadratnega pogreška $\theta = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \mathbf{X}$, kjer je \mathbf{G} matrika seštevkov istoležnih sosedov opazovanega valčnega koeficienta. Izberemo tisti parameter teksture, za katerega je verjetnost izračuna v valčnem prostoru največja. Tukaj definiramo veliko in malo okno ter izračunavamo valčne koeficiente in parametre teksture za majhno okno.

3 Ocenjevanje vlažnosti iz slik SAR

Ocenjevanje vlažnosti iz slik SAR smo v tem članku opravili z izkustvenim modelom Dubois [9], ki uporablja dvojno polarizirane odbojne koeficiente. Z uporabo zajetih radarskih podatkov odboja in meritev zemlje so empirično določeni kopolarizirani koeficienti odboja σ_{HH}^0 in σ_{VV}^0 za horizontalno in vertikalno polarizacijo izraženi kot funkcija sistemskih parametrov, kot so lokalni vpadni kot, frekvenca in parametri zemlje, dielektrična konstanta in razgibanost površine. V prvem koraku je bila raziskana povezava med razmerjem odbojnega koeficienta, vpliv različnih hrapavosti površine, vlažnosti zemlje in lokalnega vpadnega kota. V drugem koraku je bila deviacija hrapavosti površine ks nadomeščena z empirično izpeljanim členom razgibanosti $\log(ks \sin \alpha)$. Enačbe so podane kot

$$\begin{aligned} \sigma_{HH}^2 &= 10^{-2,75} \frac{\cos^{1,5} \alpha}{\sin^5 \alpha} 10^{0,028 \varepsilon' \tan \alpha} (ks \sin \alpha)^{1,4} \lambda^{0,7} \\ \sigma_{VV}^2 &= 10^{-2,37} \frac{\cos^3 \alpha}{\sin^3 \alpha} 10^{0,046 \varepsilon' \tan \alpha} (ks \sin \alpha)^{1,1} \lambda^{0,7}, \end{aligned} \quad (17)$$

kjer so α lokalni vpadni kot, ε' realni del dielektrične konstante, ks normalizirana razgibanost površja in λ valovna dolžina elektromagnetnega valovanja. Enačbi (17) predstavljata sistem enačb z dvema neznankama ks in ε' , ki ju lahko rešimo s pomočjo invertiranja empiričnega Duboisovega modela [9]

$$\begin{aligned} \varepsilon' &= \frac{\left(\log_{10} \frac{(\sigma_{HH}^0)^{0,7857}}{\sigma_{VV}^0} 10^{-0,19} \cos^{1,82} \alpha \sin^{0,93} \alpha \lambda^{0,15}\right)}{-0,024 \tan \alpha} \\ ks &= (\sigma_{HH}^0)^{1/1,14} 10^{2,75/1,4} \frac{\sin^{2,57} \alpha}{\cos^{1,07} \alpha} 10^{-0,02 \varepsilon' \tan \alpha} \lambda^{-0,5}. \end{aligned} \quad (18)$$

Poskusi so pokazali, da se algoritem dobro obnaša nad razpršenimi območji vegetacije. Za indikacijo vegetacije se lahko uporabi razmerje $\sigma_{HH}^0/\sigma_{VV}^0$. Razmerje vrednosti $\sigma_{HH}^0/\sigma_{VV}^0 > -11dB$ nakazuje prisotnost vegetacije in takšna področja niso upoštevana pri inverznem algoritmu. Vendar kot je bilo predstavljeno v [9], ta pogoj privede do neupoštevanja zelo razgibanega terena ($ks > 3$), saj jih algoritem zamenja za območja vegetacije. Po drugi strani pa so ta območja preprosto preveč razgibana za ta model in bi jih morali odstraniti. Torej je algoritem uporaben le na območju, ki ga določimo s pogojem $\sigma_{HH}^0/\sigma_{VV}^0 < 1$ in $\sigma_{HH}^0/\sigma_{VV}^0 < -11dB$. Tukaj je uporabljena tudi polinomska relacija pri ocenjevanju vsebnosti vlažnosti površja Zemlje za pretvorbo iz ε' v volumetrično vlažnost uporabimo $vol(\%) = 0.00043(\varepsilon')^3 - 0.055(\varepsilon')^2 + 2.92(\varepsilon') - 5.3$.

4 Eksperimentalni rezultati

V tem poglavju bomo prikazali učinkovitost različnih metod za odpravljanje pegastega šuma pri uporabi Duboisovega modela. Metode za odpravljanje pegastega

Tabela 1. Objektivna primerjava rekonstruiranih slik z odpravljenim šumom

T1 $\mu = 1616.57$	MSE	\hat{x}	\hat{y}/\hat{x}	y/\hat{x}
MBD	53563	1593,1	1614,1	3,2
MAP-ABM	65351	1700,6	1613,4	3,1
WGEM	48191	1603	1616,5	3,2
LUWD [1]	51775	1650	1616,4	3,2


šuma primerjamo tako, da generiramo sintetični pegasti šum in ga pomnožimo z optično sliko. Po ocenitvi šuma v sintetično generirani sliki želimo dobiti približek originalne slike. Sliki 1a in 1b prikazujeta originalno sliko in sliko z multiplikativnim pegastim šumom. Generiran šum ima tri poglede (*ang. looks*). Sliko 1b uporabimo za odstranjevanje šuma. Sliki 1c in 1d prikazujeta rekonstruirani sliki, dobljeni z metodama MAP-GMRF in MAP-ABM, ki delujeta v slikovnem prostoru. Sliki 1e in 1f prikazujeta rekonstruirani sliki, dobljeni z metodama WGEM in LUWD, ki delujeta v valčnem prostoru. Za vse rekonstruirane slike ne moremo reči, da ne vsebujejo pegastega šuma, lahko pa se približamo originalni sceni. Tabela 1 prikazuje objektivno primerjavo rekonstruiranih slik. Primerjali smo srednjo vrednost rekonstruirane in originalne slike, srednji kvadratični pogrešek, srednjo vrednost razmerja med originalno in rekonstruirano sliko, ki predstavlja pegasti šum in število pogledov pegastega šuma. Iz Tabele 1 in rekonstruiranih slik 1c-1e lahko povzamemo, da metoda WGEM, ki deluje v valčnem prostoru, daje najboljše rezultate glede srednjega kvadratičnega pogreška, sledita ji MAP-GMRF in MAP-ABM. Vse metode dobro ohranjajo srednjo vrednost originalne slike in približno enako ocenjujejo oz. odstranjujejo pegasti šum. Vse tri metode smo testirali s slikami SAR. Ker je pegasti šum v slikah koreliran, ga s podotipanjem slike SAR dekoliramo in tako izboljšamo odstranjevanje šuma, vendar izgubimo na resoluciji slike.

4.1 Ocenitev vlažnosti s pomočjo Duboisovega modela

Ocenitev vlažnosti s pomočjo Duboisovega modela smo izvedli nad dualno polariziranimi slikami SAR. Polarizirane slike so predstavljene s kompleksnimi števili in predstavljajo relativni odboj elektromagnetnega valovanja od površja Zemlje, ki ga pogosto označujemo z β^0 . Zato smo slike SAR najprej radiometrično umerili s pomočjo formule:


$$\sigma^0 = (k_s |DN|^2 - NEBN) \sin \alpha, \quad (19)$$

kjer je k_s kalibracijski in skalirni faktor, ki je podan za posamezno sliko. DN pomeni intenzivnost točk v sliki, $NEBN$ je ekvivalenten šum β^0 in α lokalni vpadni kot med točko na Zemlji oz. sliki in satelitom. $NEBN$ je definiran kot $NEBN = k_s \sum_{i=0}^{deg} (\tau - \tau_{ref})$, kjer je deg stopnja polinoma, i pomeni koeficient polinoma, τ_{ref} je



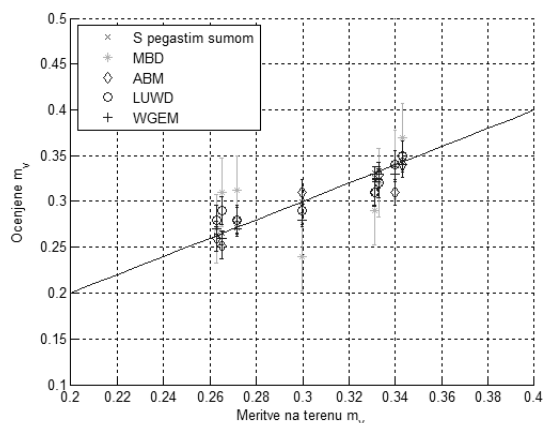
Slika 1. (a) Originalna slika. Original image. (b) Slika s sintetičnim šumom. Image with synthetic speckle. (c) Rekonstruirana po metodi MAP-GMRF. MAP-GMRF despeckled image. (d) Rekonstruirana po metodi MAP-ABM. MAP-ABM despeckled image. (e) Rekonstruirana po metodi WGEM. WGEM despeckled image. (f) Rekonstruirana po metodi LUWD [1]. LUWD despeckled image.

referenčna točka, τ pa pripada intervalu $\tau_{\min} - \tau_{\max}$ v odvisnosti od stopnje polinoma, ki opisuje šum v sliki. Slika 2a prikazuje originalno sliko SAR v formatu β^0 in HH polarizacijo, 2b pa sliko SAR v formatu σ^0 . Slike 2c-2f prikazujejo slike z odpravljenim šumom po metodah MAP-GMRF, MAP-ABM, WGEM in LUWD [1]. Iz razmerja med originalno in rekonstruirano sliko dobimo ocenjen pegasti šum. Z merjenjem srednje vrednosti ocenjenega pegastega šuma, ki mora biti blizu 1 in vrednosti ENL, lahko vidimo, kako dobro posamezna metoda odstranjuje šum. Za slike, prikazane na 2c-2f, dobimo ENL vrednosti, enake 1, 4, 1, 9, 1, 5 in 1, 6 ter srednje vrednosti 1, 05, 0, 99, 1, 01, 0, 99. Vidimo, da vse metode dobro ocenijo pegasti šum, le metoda ABM daje bolj gladko sliko, kar je posledica izključevanja robov pri rekonstrukciji slike. Graf na sliki 3 prikazuje realne meritve na terenu in ocenjene meritve s pomočjo dualno polariziranih slik SAR. Izbrali smo teren brez vegetacije in tako zagotovili enojen odboj od površja. Primerjali smo izmerjeno vlažnost s senzorjem vlage in ocenjeno vlažnost iz slik SAR s pegastim šumom in s slikami brez pegastega šuma. Izvedli smo 200 meritev na terenu v naključnem zaporedju na območju 10×5 kilometrov, kot je območje zajemanja satelita TerraSAR-X. Resolucija v smeri preleta satelita je 2,2 m in pravokotno na let 1,1 m. Ena meritev na Zemlji se izračuna s pomočjo območja 3×3 točk na sliki. Meritve ne odstopajo bistveno od srednje vrednosti, ker so bile izvedene sočasno s preletom satelita, ki gre čez območje ob 5.15 po lokalnem času. V času zajemanja merilnih točk je prevladovalo suho in lepo



Slika 2. (a) Originalna slika SAR β^0 polarizirana HH (2009 ©DLR). Original SAR SLC image in β^0 format. (b) Slika SAR predstavljena z σ^0 . Normalized and calibrated σ^0 image. (c) Rekonstruirana po metodi MAP-GMRF. MAP-GMRF despeckled image. (d) Rekonstruirana po metodi MAP-ABM. MAP-ABM despeckled image. (e) Rekonstruirana po metodi WGEM. WGEM despeckled image. (f) Rekonstruirana po metodi LUWD [1]. LUWD despeckled image.

vreme. Iz slike 2f ugotovimo, da s pomočjo slik SAR



Slika 3. Ocenjene vlažnosti tal z različnimi metodami. Estimated soil moisture using different methods.

v pasu X lahko izmerimo vlažnost terena. Odstopanja od dejanskih meritev so relativno majhna. Meritve smo izvedli na relativno suhem terenu, ker je v času zajemanja SAR slik na Dravskem polju prevladovalo suho in lepo vreme. Pričakujemo večja odstopanja pri več kot 30-odstotni vlažnosti, ker tam model ne deluje dovolj dobro. Uporabljen model je namenjen radarskim podatkom v pasu L, saj ta valovna dolžina prodira skozi vegetacijo. Primerjali smo štiri metode za odpravljanje pegastega šuma iz slik SAR in ugotovili, da so odstopanja

od izmerjenih vrednosti v določenih točkah majhna zato, ker metode za odpravo pegastega šuma povprečijo območje v okolici točke opazovanja. Metode kot so ABM, LUWD, WGEM in MBD, vse dobro ohranjajo srednjo vrednost originalne slike in lokalne srednje vrednosti, zato so rezultati z vsemi metodami primerljivi. Za praktično uporabo priporočamo izbiro računsko najhitrejše metode, to je WGEM.

5 Sklep

V tem članku smo predstavili metode za odpravljanje pegastega šuma iz slik SAR in preverili uporabnost izboljšanih slik za ocenitev vlažnosti zemlje iz slik SAR. Uporabljene slike SAR so posnete v pasu X. Elektromagnetni valovi se odbijajo od vegetacije, zato se to območje ponavadi ne uporablja za ocenitev vlažnosti. Metode za odpravljanje šuma uporabljajo Markova naključna polja v slikovnem in valčnem prostoru. Vse metode so najmodernejše in dajejo dobre rezultate pri ocenjevanju oz. odstranjevanju pegastega šuma. Eksperimentalni rezultati so pokazali, da je izboljšane slike SAR mogoče porabiti za ocenitev vlažnosti s pomočjo Duboisovega modela. Vse prikazane metode dajejo dobre rezultate ocenitve vlažnosti, saj dobro ohranjajo lokalno srednjo vrednost slike SAR.

6 Literatura

- [1] F. Argenti, T. Bianchi, and L. Alparone, "Multiresolution map despeckling of sar images based on locally adaptive generalized gaussian pdf modeling," *IEEE Trans. Image Process.*, vol. 15, no. 22, pp. 3385–3399, Nov. 2006.
- [2] D. O. Duda, P. E. Hart, and D. Stork, *Pattern Classification*. Reading, MA: John Wiley and Sons, 1972.
- [3] B. Gergič, P. Planinšič, D. Gleich, and Žarko Čučej, "Izbira filterbank za komprimiranje kompleksnih podatkov sar," *Elektroteh. vestn.*, vol. 66, no. 4-5, pp. 237–281, 1999.
- [4] D. Gleich and M. Datcu, "Gauss-markov model for sar image despeckling," *IEEE Signal Process. Lett.*, vol. 13, no. 6, pp. 365–368, June 2006.
- [5] —, "Wavelet-based despeckling of sar images using gauss-markov random fields," *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 12, pp. 4127–4143, Dec 2007.
- [6] M. Soccorsi, D. Gleich, and M. Datcu, "Huber markov model for sar image despeckling," *IEEE Geosci. Remote Sens. Lett.*, vol. 7, pp. 63–67, Jan 2010.
- [7] M. Walessa and M. Datcu, "Model-based despeckling and information extraction from sar images," *IEEE Trans. Geosci. Remote Sens.*, vol. 38, pp. 2258–2269, Sep. 2000.
- [8] M. Hebar, D. Gleich, and Z. Cucej, "Auto-binomial model for sar image despeckling and information extraction," *IEEE Trans. Geosci. Remote Sens.*, vol. 47, no. 8, pp. 2818–2835, Aug 2009.
- [9] P. C. Dubois, van J Zyl, and T. Engman, "Measuring soil moisture with imaging radars," *IEEE Trans. Geosci. Remote Sens.*, vol. 33, no. 4, pp. 916–926, July 1995.