

Ataskaita už 2023 doktorantūros metus

Doktorantė: Neringa Urbonaitė
Vadovas: Prof. habil. dr. Leonidas Sakalauskas

Vilniaus Universitetas
Duomenų mokslo ir skaitmeninių technologijų institutas

2023 kovo 21 d.

Disertacijos tema

Disertacijos tema:

Fraktalinio Brauno Lauko tyrimas ir taikymas daugiamačių duomenų modeliavime

Vadovas:

Prof. habil. dr. Leonidas Sakalauskas

Pradžios pabaigos metai:

2019-2023

Disertacijos rengimo planas

1 lentelės Visų studijų planas

Studijų metai	Dalyvavimas konferencijose				Publikacijos		
	Tarptautinėse		Nacionalinėse		Su citav. rodikliu		Būklė
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	
I (2019/2020)				1			
II (2020/2021)	1	1			1	1	Publikuota
III (2021/2022)	1	3					
IV (2022/2023)					1		Out for review
Iš viso:		4		1	2	1	

Disertacijos rengimo planas

Ataskaitinis studijų pusmetis

2 lentelės. Ataskaitinis studijų pusmetis (2022/2023 – I pusmetis).

	Publikacijos (tik su citavimo rodikliu)	
Eil. Nr.	Bibliografinis aprašas	Būsena
1	Neringa Urbonaite. Leonidas Sakalauskas. A Novel Fractional Kriging Method for Multi-Output Data Modelling. Žurnalas: Stochastic models.	Out For Review Įkelta lapkričio 30d.

2 lentelės Konferencijos. Studijų metai (2019/2023).

Dalyvavimas tarptautinėse konferencijose	
Eil. nr	Aprašas
1	Neringa Urbonaitė, Leonidas Sakalauskas <i>Application of vector fractal Brownian field model for data extrapolation and kriging</i> , The 19th Conference of the Applied Stochastic Models and Data Analysis International Society ASMDA2021 and DEMOGRAPHICS2021 WORKSHOP (nuotolinė), Atėnai, Graikija, 2021.
2	Neringa Urbonaitė, Leonidas Sakalauskas <i>Investigation of Fractional Brownian Vector Fields</i> , Joint ICTP-IUGG Workshop on Data Assimilation and Inverse Problems in Geophysical Sciences (nuotolinė), Trieste, Italija. 18-29 Spalis, 2021.
3	Neringa Urbonaitė, Leonidas Sakalauskas <i>Multivariate Data Modeling: Methods and Challenges</i> , International Symposium on Applied Geoinformatics ISAG2021 (nuotolinė). Ryga, Latvija. 2-3 Gruodis, 2021.
4	Neringa Urbonaitė, Leonidas Sakalauskas <i>Construction of a Kriging Model using Fractional Brownian. Vector Fields</i> . 7th Stochastic Modeling Techniques and Data Analysis International Conference and Demographics 2022 Workshop. SMTDA 2022 and Demographics 2022. Atėnai, Graikija, 2022.

3 lentelės Publikacijos. Studijų metai (2019/2023).

Publikacijos (tik su citavimo rodikliu)		
Eil. Nr.	Bibliografinis aprašas	Būklė
1	Ramanauskaitė, Simona; Urbonaitė, Neringa; Grigaliūnas, Šarūnas; Preidys, Saulius; Trinkūnas, Vaidotas; Venčkauskas, Algimantas. Educational organization's security level estimation model // Basel : MDPI. ISSN 2076-3417. 2021, vol. 11, iss. 17, art. no. 8061, p. 1-19. DOI:	Publikuota. Registruota eLABa sistemoje 10.3390/app11178061 .

Mokslinių tyrimų ir disertacijos rengimo etapai

2.4. Gautų duomenų analizė, apibendrinimas, išvadų parengimas:

2.4.1 Gautų rezultatų statistinė analizė;

2.4.2 Rezultatų apibendrinimas, esminių rezultatų išskyrimas;

2.4.3 Išvadų parengimas.

2022 m. spalio mėn. –
2023 m. kovo
mėn.

Visi išvardyti metodai skirti modeliuoti ir generuoti duomenis kai juose yra trendas:

Sudarytas FvBI'o realizacijų generavimo metodas (psl. 37 -39).

Sudarytas didžiausio tikėtimumo metodas įvertinti parametrams (psl. 42).

Sudaryta funkcija įvertinti atskirai trendo parametrams.

Sudarytos kriginio prognozės lygtys. (psl. 50-51).

Disertacijos uždaviniai

Tyrimo objektas: Fraktalinis vektorinis Brauno laukas

Tikslas: Skirtų daugiamačiams duomenims ir jų sąsajoms vertinti, generuoti, prognozuoti, taikyti, algoritmų kūrimas, remiantis Fraktalinio vektorinio Brauno lauko modeliu, kai yra stebėjimų trūkumas.

Uždaviniai:

- 1 Sukurti FvBl'o modelį;
- 2 Sudaryti FvBl'o realizacijų generavimo algoritmą;
- 3 Sudaryti FvBl'o vertinimo algoritmą taikant didžiausio tikėtimumo metodą (DT) ir palyginti jį su variogramos (V) metodu;
- 4 Sudaryti metodą daugiamačių duomenų ekstrepoliavimui taikant FvBl'o modelį;
- 5 Pritaikyti sukurtą metodą praktiniams uždaviniams.

Fraktalinis vektorinis Brauno laukas

Tarkime Gauso procesas funkcijoms $z \sim \mathcal{GP}(\mu, k)$ yra apibrėžiamas vidurkiu μ ir kovariacija k . Darome prielaidą, kad bet kokiam įvesties vektoriui $x = x_1, \dots, x_k$, $x_i \in \mathbb{R}^p$ ir atsakui $y = y_1, \dots, y_k$, išėjimus generuoja funkcija $y = z(x)$, kur $z(x) : \mathbb{R}^p \rightarrow \mathbb{R}$.

Funkcijų rinkinys $[z(x_1), \dots, z(x_k)]$ skalariniam atvejui atitinka normalųjį skirstinį:

$$[z(x_1), \dots, z(x_k)] \sim \mathcal{N}(\mu(x), k(x, x')),$$

Standartinė fraktalinio Brauno išraiška apibrėžiama:

$$\text{cov}[z(x), z(x')] = k(x, x') = \frac{1}{2}(\|x\|^{2H} + \|x'\|^{2H} - \|x - x'\|^{2H})$$

kur $\|\cdot\|$ Euklido norma \mathbb{R}^k .

$$k(x, x') = \|x - x'\|^H.$$

Fraktalinis vektorinis Brauno laukas

Turint k stebėjimų porų $(x_i, y_i)_{i=1}^k$, tegul $\mathbf{Y} = (y_1, \dots, y_k)$, $y_i \in \mathbb{R}^m$ yra atsako vektorius, o $\mathbf{X} = (x_1, \dots, x_k)$ $x_i \in \mathbb{R}^p$ - įvesties vektorius.

Pagrindinis tikslas - sudaryti fraktalinį modelį, kurio forma:

$$\mathbf{Y} = \mathbf{Z}(\mathbf{X}), \quad (1)$$

kur \mathbf{Z} - matrica, funkcija, įvertinta skirtinguose mokymo taškuose. Todėl daroma prielaida, kad vektoriniai kintamieji $\mathbf{Z} : \mathbb{R}^{p \times k} \rightarrow \mathbb{R}^{m \times k}$ atitinka Gauso procesą $\mathbf{Z} \sim \mathcal{GP}(\mu \mathbf{1}^\top, \mathbf{K} \otimes \Omega)$, kur $\mu \in \mathbb{R}^k$ yra vektorius, kurio komponentės yra kiekvieno išėjimo vidurkio funkcijos $\mu(x_i)_{i=1}^k$, o \mathbf{K} yra blokinė matrica.

Fraktalinis vektorinis Brauno laukas

Šiuo atveju \mathbf{Y} vidurkis yra žinomų bazinių funkcijų (pvz., tiesinių arba kvadratinė) vektorius $f(x) = [f_1(x), f_2(x), \dots, f_k(x)]^\top$, $f(x) \in \mathbb{R}^q$, o $\Gamma = [\Gamma_1, \Gamma_2, \dots, \Gamma_k]^\top$, $\Gamma \in \mathbb{R}^d$ yra nežinomų parametrų vektorius.

$$\mu(x) = \Gamma f(x)$$

Trendo parametrai apskaičiuojami:

$$\hat{\Gamma}(x) = (f(x)(f(x)A_{xx}^{-1})^\top)^{-1} f(x)A_{xx}^{-1} \mathbf{Y}^\top. \quad (2)$$

Parametrų vertinimas

Taikytas didžiausio tikėtinumo metodas. Sudaroma tikėtinumo funkcija, toliau diferencijuojama. Išvestinė prilyginama nuliui.

$$\hat{\Omega}_{trend} = -\frac{1}{k}(\mathbf{Y} - \mathbf{Y}A_{xx}^{-1}f(x))^{\top} (f(x)A_{xx}^{-1}f(x)^{\top})^{-1}f(x) \quad (3)$$
$$A_{xx}^{-1}(\mathbf{Y} - \mathbf{Y}A_{xx}^{-1}f(x))^{\top} (f(x)A_{xx}^{-1}f(x)^{\top})^{-1}f(x).$$

$$\hat{H}_{MLE_{trend}} = \operatorname{argmax}_{\hat{H}} \left[\frac{1}{m} \ln(|\hat{\Omega}_{trend}|) + \frac{1}{k} \ln(|A_{xx}|) \right]. \quad (4)$$

Didžiausio tikėtinumo funkcija minimizuojama taikant Golden Section Search metodą.

Choleskio metodas

2 algoritmas Choleskio dekompozicija pagrįstas FvBl generavimo algoritmas su trendu

Input : Koordinatės $\mathbf{X} \in \mathbb{R}^{K \times 2}$, realizacijų dydis K , stulpelių skaičius M , Hursto parametro vertė $H \in [0,1)$, trendo parametrų matrica Γ , trendo funkcijos $f(x)$.

Output: FvBl imituojamų verčių matrica $\mathbf{Z} \in \mathbb{R}^{K \times M}$.

4 Procedure `FracField(H, X, K, M, Γ , $f(x)$)`:

5 | Apskaičiuokite $K \times K$ kovariacijos matricą pagal lygtį (23);

| Sukuriama $M \times M$ teigiamai apibrėžta matrica Ω ;

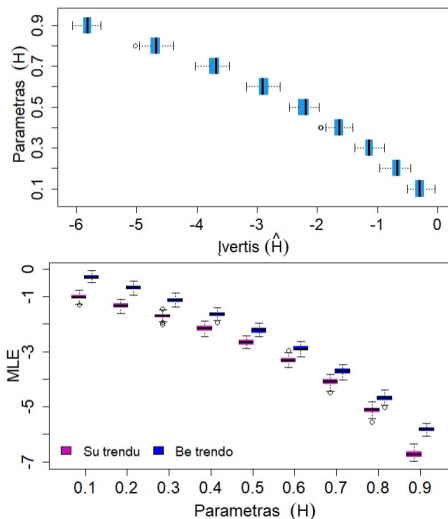
| Taikykomas Choleskio išskaidymas $C = Chol(B_{xx})$ ir $L = Chol(\Omega)$

| Generuojami vektoriai $\zeta \sim \mathcal{N}(0,1)$, $\zeta \in \mathbb{R}^{K \times M}$;

| Kiekvienai trendo funkcijai paskaičiuojamos vertės ir sudaroma jų matrica. $\mathbf{Z} = L\zeta C^T + \Gamma f(x)$

6 return

Choleskio metodos



Mokslinių tyrimų ir disertacijos rengimo tolimesni etapai

- Ataskaitos rengimas.
- Bendrųjų išvadų formulavimas.

Ačiū!