

# Ataskaita už 2021 doktorantūros metus

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

Vilniaus Universitetas  
Duomenų mokslo ir skaitmeninių technologijų institutas

2021 rugsėjo 30 d.

Disertacijos tema:

**Fraktalinio Brauno Lauko tyrimas ir taikymas daugiamatį duomenų modeliavime**

Vadovas:

Prof. habil. dr. Leonidas Sakalauskas

Pradžios pabaigos metai:

2019-2023

# Disertacijos rengimo planas

Studijų metai	Egzaminai		Konferencijos		Publikacijos
	Planas	Įvykdyta	Planas	Įvykdyta	Planas
I 2019-2020	2	2	1	1	—
II 2020-2021	<b>2</b>	<b>2</b>	0	<b>1</b>	1
III 2021-2022	—	—	1	—	—
IV 2022-2023	—	—	1	—	1
Iš viso	4	4	2	1	2

lentelė 1: Disertacijos rengimo planas

Einamieji studijų metai (III: 2021/2022).

Egzaminai		Konferencijos		Publikacijos	
Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta
Fundamentalieji informatikos ir informatiko inžinerijos metodai	Išlaikyta	DAMSS'2019			
Gilieji neuroniniai tinklai	2021 – 06 Išlaikyta	ASMDA 2021 birželio 1- 4 d. Conference of the Applied Stochastic Models and Data Analysis	Investigation of fractional Brownian fields	1	1

lentelė 2: Disertacijos rengimo planas

# Mokslinių tyrimų ir disertacijos rengimo etapai

	Darbo pavadinimas	Atlikimo terminai	Pastabos
1	Mokslinių tyrimų disertacijos tema apžvalga ir analizė (Lietuvoje ir užsienyje): 1. Atlikti daugiamatį Kringingo modelių apžvalgą. 2. Nustatyti (identifikuoti) mokslines problemas, kylančias uždaviniuose.	2019 m. spalio mėn. – 2020 m. rugšėjo mėn.	Parengta mokslinė literatūros apžvalga.
2	<b>Mokslinio tyrimo vykdymas:</b> 2.1. Tyrimo metodikos sudarymas; 2.1.1 Tyrimo metodikos iškeltam uždaviniui spręsti parinkimas; 2.1.2 Teorinio ir empirinio tyrimų suplanavimas pagal pasirinktą metodiką. <b>2.2. Teorinis tyrimas:</b> 2.2.1 Fraktalinių Brauno laukų (FBL) savybių tyrimas; 2.2.2 FBL realizacijų kompiuterinio imitavimo metodo sukūrimas. 2.3.1 FBL pritaikymas daugiamatiam kringingui ir ekstrepoliavimui; 2.3.2 Atstiktinių laukų parametru vertinimo metodų: semivariogramos ir didžiausio tikėtimumo algoritmų sukūrimas. 2.3.3 Kompiuterinių eksperimentų atlikimas generuojant FBL realizaciją imtis ir palyginant jų parametru vertinimo rezultatus su kitais atsitiktiniais laukais;	2020 m. spalio mėn. – 2021 m. balandžio mėn.  2020 m. gegužės mėn. – 2021 m. rugšėjo mėn.  2021 m. lapkričio mėn. – 2022 m. rugšėjo mėn.	Parengta FBL modelių apžvalga.  Sudarytas Fraktalinis vektorinis Brauno lauko (FvBl) modelis.  Sudarytas FvBl'o realizacijų generavimo metodas.  Sudaryti vertinimo metodai: didžiausio tikėtimumo ir variogramos.  Atliktas Monte Carlo eksperimentas.  Sudarytas kringingo metodas su FvBl'o kovariancijų matrica.

**Tyrimo objektas:** daugiamačiai duomenų modeliavimo metodai, skirti vertinti, modeliuoti, generuoti fraktalinį vektorinį Brauno lauką.

**Tikslas:** Algoritmų kūrimas, skirtų daugiamačiams duomenims ir jų sąsajoms vertinti, generuoti, prognozuoti, kai yra stebėjimų trūkumas, taikant fraktalinį vektorinį Brauno lauko modelį.

## 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.

---

**Algorithm 1:** Krigingas

---

**Input** :  $X = (x^{(1)}, x^{(2)}, \dots, x^{(K)})$ ,  $Z = (z_{(1)}, z_{(2)}, \dots, z_{(K)})$ ,  $E_i = 1$ ,  
 $1 \leq i \leq K$ ,  $X_{new} = (x_{new}^{(1)}, x_{new}^{(2)}, \dots, x_{new}^{(P)})$ ,  $1 \leq p \leq P$ ,  $H$

**Output:**  $Y(X_{new})$

```
1 for  $i \leftarrow 1$  to  $K$  do
2   | for  $j \leftarrow 1$  to  $K$  do
3   |   |  $A_{i,j} = ((x^i - x^j) \cdot (x^i - x^j)^T)^H$ 
4   |   end for
5   end for
6 Function  $Prognosis(A, H, K, x_{new})$ :
7   | for  $j \leftarrow 1$  to  $K$  do
8   |   |  $b_i = ((x_{new} - x^i) \cdot (x_{new} - x^i)^T)^H$ 
9   |   end for
10  |  $y = Z^T A^{-1} (b + E \frac{(1 - E^T A^{-1} b)})$ ;
11 return
12 for  $p \leftarrow 1$  to  $P$  do
13 |  $Y(X_{new}) = Prognosis(A, H, K, x_{new}^{(p)})$ 
14 end for
```

---



# Fraktalinio vektorinio Brauno lauko modelis

Tarkime, turime duomenų rinkinį:  $X = (x^{(1)}, x^{(2)}, \dots, x^{(k)})$ ;  
 $x_{(i)} \in \mathbb{R}^d$ ;  $1 \leq i, j \leq k$ ;  $\mathbf{1} = (1, 1, \dots, 1)$ ,  $A = A_{i,j}$

$$A = ((x_i - x_j)^T (x_i - x_j))^H \quad (1)$$

$$B_H(X) = 2 \frac{\mathbf{1}\mathbf{1}^T}{\mathbf{1}^T A^{-1} \mathbf{1}} - A \quad (2)$$

$H$  - Hursto indeksas

Taikant darbe formulę (3) nereikia žinoti koordinatų pradžios, kitaip nei tradiciniame apibrėžime pagal A. Kolmogorovą.

[3] N. Pozniak, L. Sakalauskas ir L. Saltyte, Kriging model with fractional euclidean distance matrices,“ Informatica, t. 30, pp. 367-390, 2019.

Vienas iš metodų įvertinti parametą  $H$  yra taikant variogramą. Tai fundamentalus modelis skirtas erdvinių porcesų modeliavimui.

Geostatistikos darbuose žinoma, kad variograma iš atsitiktinės funkcijos gali būti suskaidyta į atskirus taškus.

$$V_{(1)} = \frac{2}{k(k-1)} \left( \sum_{i=1}^{k-1} \sum_{j=1}^k (z_i - z_j)(z_i - z_j) \right)$$

$$V_{(2)} = \frac{\sum_{ii=1}^m \sum_{jj=1}^m \left( \sum_{i=1}^{k-1} \sum_{j=1}^k (z_{ii,i} - z_{ii,j})(z_{jj,i} - z_{jj,j}) \right) \left( (x_i - x_j)^T (x_i - x_j) \right)^H}{\sum_{i=1}^k \sum_{j=1}^k \left( (x_i - x_j)^T (x_i - x_j) \right)^{2H}}$$

$$V(H) = V_{(1)} - V_{(2)} \quad (3)$$

Iš formulės (6) optimali parametro reikšmė įvertinama minimizuojant pagal  $H$ .

Taikant Didžiausio tikėtinumo metodą įvertinamos tokios parametrų reikšmės, su kuriomis gaunami rezultatai yra labiausiai tikėtini duotajam modeliui.


$$L = \frac{1}{K} (Z B_H(X)^{-1} Z^T - \frac{(Z B_H(X)^{-1} \mathbf{1})}{\mathbf{1}^T B_H(X)^{-1} \mathbf{1}}) \quad (4)$$

$$G(H) = \frac{1}{m} \ln(L) + \frac{1}{k} \ln(B_H(X)) \quad (5)$$

Tradiciskai yra taikomas variogramos metodas, o didžiausio tikėtinumo metodo taikymas erdvinių duomenų analizei yra mažai tyrinėtas.

Didžiausio tikėtinumo metodą bandoma dažniausiai sudaryti tik procesams per Kolmogorovo tipo kovariacijų funkciją.

# Fraktalinis vektorinis Brauno laukas




pav. 1:  $H = 0.1$



pav. 2:  $H = 0.9$




pav. 3:  $H = 0.1$




pav. 4:  $H = 0.9$


# Monte Karlo statistinis eksperimentas: DT metodas




pav. 5: DT: Vidurkiai  
įvertintų parametru  $H$



pav. 6: DT: Standartiniai  
nuokrypiai parametru  $H$



pav. 7: V



pav. 8: V

mėn.	2017	2018	2019	2020
1	0.84	0.81	0.83	0.83
2	0.81	0.82	0.80	0.81
3	0.78	0.73	0.71	0.71
4	0.67	0.72	0.70	0.75
5	0.75	0.69	0.65	0.74
6	0.72	0.77	0.72	0.66
7	0.70	0.76	0.65	0.71
8	0.63	0.67	0.70	0.70
9	0.60	0.67	0.59	0.66
10	0.66	0.65	0.64	0.64
11	0.73	0.76	0.71	0.78
12	0.72	0.83	0.79	0.76

lentelė 3: Rezultatai, Hursto įverčiai

---

**Algorithm 2:** Shepard's Method

---

**Input** :  $X = (x^{(1)}, x^{(2)}, \dots, x^{(K)})$ ,  $Z = (z^{(1)}, z^{(2)}, \dots, z^{(K)})$ ,  $E_i = 1$ ,  
 $1 \leq i \leq K$ ,  $X_{new} = (x_{new}^{(1)}, x_{new}^{(2)}, \dots, x_{new}^{(P)})$ ,  $1 \leq p \leq P$ ,  $D$

**Output:**  $Y(X_{new})$

```
1 Function  $W(x_{new}, D)$  :  
2   | for  $j \leftarrow 1$  to  $K$  do  
3   |   |  $w_i = \frac{1}{((x^i - x_{new}) + (x^i - x_{new}))^D}$   
4   |   end for  
5 return  
6 Function  $Prognosis(x_{new}, D)$  :  
7   |  $w = W(x_{new}, D)$   
8   |  $Y = \frac{Z \cdot w}{E \cdot w}$   
9 return  
10 for  $p \leftarrow 1$  to  $P$  do  
11 |  $Y(X_{new}) = Prognosis(x_{new}^{(p)}, D)$   
12 end for
```

---

Sunkiųjų metalų (Cd, Cu, Pb, Zn) ir aukščio matavimai prie Maso upės (Olandija).  $m = 5$ ;  $K = 155$ ;  $P = 3103$ .




pav. 9: Matavimai




pav. 10: Gardelė



# Krigingo modelis




# Šepardo modelis




# Zn [ppm]




## Krigingo modelis



## Šepardo modelis



## Aukštis [m]



## Disertacijos rengimo planas

- 1 Metodų taikymas praktiniams uždaviniams;
- 2 Sudalyvauti konferencijoje;
- 3 Parengti publikaciją;

Ačiū!