

ექსპერტული ცოდნის ნაკადის
პროგნოზის ამოცანის მანქანური
სწავლების ახალი ტექნოლოგიის შესახებ
**On Machine Learning New Technology
for the Prediction Problem
of Expert Knowledge Stream**

პროფ. გია სირბილაძე,
ივ. ჯავახიშვილის სახ. თბილისის სახელმწიფო
უნივერსიტეტი

Prof. Gia Sirbiladze
Iv. Javakhishvili Tbilisi State University
GEORGIA

ENS 2020, February 3-7,
Tbilisi, Georgia

ექსპერტული ცოდნის ნაკადის (ეცნ) შესაძლებლობითი მოდელი

1. ეცნ-ის აგების კონსტრუქცია
2. ეცნ-ის შესაძლებლობითი მოდელი - კლასიფიკატორის შეფასება მანქანური სწავლებით
3. პროგნოზის ამოცანა ეცნ-ის მოდელისთვის
4. მაგალითი

სუსტად სტრუქტურირებული პროცესების

მოდელირების ახალი ფაზი-ტექნოლოგია

1. ამოცანა ეხება რთული და/ან ექსტრემალურ ევოლუციურ მოვლენებზე დროში ექსპერტული შეფასებების პროცესის - ექსპერტული ცოდნის ნაკადის (ეცნ) ანალიზისა და სინთეზის პრობლემებს.
2. ასეთ პროცესებს - სუსტად სტრუქტურირებული პროცესები ეწოდება, როდესაც ევოლუციური სისტემის ობიექტებს შორის მიმართება ექსპერტული ცოდნის ბაზაზე კონსტრუირებული ობიექტური ინფორმაციის უკმარობის ან საერთოდ არ არსებობის გამო.
3. ეცნ-ის გამოყენება დღეს აქტუალურია საზოგადოებასა და ბუნებაში მიმდინარე რთული და ანომალური მოვლენების შესასწავლად. მაგ. საინჟინრო ნოვაციური ამოცანები, მონაცემთა მეცნიერების პრობლემები, ეკონომიკისა და ბიზნესის სირთულეები, და სხვ.

სუსტად სტრუქტურირებული პროცესების მოდელირების ახალი ფაზი-ტექნოლოგია

1. მოდელირება ინფორმაციის განსაზღვრულობის კარგვას იწვევს...ის ამოცანის გარკვეულ დეტალიზაციას აღწერს...
2. ასევეა ეცნ-ის მოდელირებაში. ცხადია ექსერტული ცოდნის შეფასების სინტაქსი მარტივი და მოხერხებული უნდა იყოს ცოდნის წარმოდგენის მაღალი აქტოვობის მისაღწევად.
3. მიუხედავად ამ მოხერხებულობისა, შესაბამისი სემანტიკური კავშირების აგებისას ჩნდება უზუსტობისა და განუზღვრელობის დუალური ფენომენი.
4. აიგება ალბათური, ფაზი, მათი შერეული თუ სხვა ტიპის განუზღვრელობის შემცველი მოდელები.
5. აქ განვიხილავთ ეცნ-ის ახალ ფაზი-მოდელს.

ეცნ-ის ახალი სუსტად სტრუქტურირებული დინამიკური მოდელი

Let $D = \{d_1, d_2, \dots, d_n\}$

be the set of possible states (in our case possible decisions) of the evolutionary system, observed by the expert.

The fuzzy trajectory of expert knowledge reflections on the possible decisions, with respect to some fuzzy term, given in certain time moments, will have the following form:

$$\left\langle \hat{K}_* = \hat{K}_*(d, t); \quad \hat{K}^* = \hat{K}^*(d, t) \right\rangle$$
$$t = 0, 1, \dots, s, \quad d \in D.$$

Let's introduce the following finite set of compatibility levels for some natural number N

$$F_N = \left\{ \frac{0}{N}, \frac{1}{N}, \dots, \frac{N}{N} \right\} \subset [0, 1]$$

ეცნ-ის ახალი სუსტად სტრუქტურირებული დინამიკური მოდელი

We consider some discretization of fuzzy transition operators (FTO) which belong to the following set:

$$\Phi_N = \{ \tilde{\rho}_N \mid \tilde{\rho}_N : D^2 \rightarrow F_N \}$$

Our goal is to construct the FTO from Φ_N in which the following deviation achieves its minimum:

$$\Delta = \sum_{d \in D} \sum_{t=0}^s \left[\left| \tilde{K}_N^*(d, t) - \hat{K}^*(d, t) \right| + \left| \tilde{K}_{*N}(d, t) - \hat{K}_*(d, t) \right| \right],$$

We use the finite possibilistic extremal model of expert knowledge stream:



ეცნ-ის ახალი სუსტად სტრუქტურირებული დინამიკური მოდელი

$$\tilde{K}_{*N}(d, t) = \int_X \langle \tilde{\rho}_N(d', d) \vee \tilde{K}_{*N}(d', t-1) \rangle \circ \hat{Pos}_{t-1}(\cdot); \quad d \in D, \quad t = 1, 2, \dots, s$$

$$\tilde{K}_N^*(d, t) = \int_X \langle \tilde{\rho}_N(d', d) \wedge \tilde{K}_N^*(d', t-1) \rangle \circ \hat{Nec}_{t-1}(\cdot);$$

$$\tilde{K}_{*N}(d', 0) \equiv \hat{K}_*(d', 0); \quad \tilde{K}_N^*(d', 0) \equiv \hat{K}^*(d', 0)$$

We use possibility and necessity measures with their distribution, derived from the expert knowledge stream:

$$\hat{Pos}_{t-1}(B) = \frac{\bigvee_{d \in B} \hat{K}_*(d, t-1)}{\bigvee_{d \in D} \hat{K}_*(d, t-1)}, \quad .$$

$$\hat{Nec}_{t-1}(B) = 1 - \frac{\bigvee_{d \notin B} \hat{K}^*(d, t-1)}{\bigvee_{d \in D} \hat{K}^*(d, t-1)}$$

$$\forall B \subset D, t = 1, 2, \dots, s$$

ეცნ-ის ფაზი-მოდელის კლასიფიკატორის აგება

მანქანური სწავლების მიახლოებით

Even for smaller values of N the cardinality of the set of fuzzy transition operators (FTO) is too large. Thus, it is not efficient to simply try all possible variants and take the smallest deviation .

For this reason, it was decided to solve this problem using Machine Learning (ML) approach based on a genetic algorithm (GA) for identification of FTO.

If $\hat{\rho}_N$ is some optimal estimation, then the modelling of the process of expert knowledge stream will be continued in moments:

$$s + 1, s + 2, \dots, \tau; \quad \tau \geq 1$$

ეცნ-ის ფაზი-მოდელის კლასიფიკატორის აგება

მანქანური სწავლების მიახლოებით

$$\tilde{K}_{*N}(d, t) = \int_X \langle \hat{\rho}_N(d', d) \vee \tilde{K}_{*N}(d', t-1) \rangle \circ Pos_{t-1}(\cdot)$$

$$\tilde{K}_N^*(d, t) = \int_X \langle \hat{\rho}_N(d', d) \wedge \tilde{K}_N^*(d', t-1) \rangle \circ Nec_{t-1}(\cdot)$$

$$Pos_{t-1}(B) = \frac{\bigvee_{d' \in B} \tilde{K}_{*N}(d', t-1)}{\bigvee_{d' \in D} \tilde{K}_{*N}(d', t-1)};$$

$$Nec_{t-1}(B) = 1 - \frac{\bigvee_{d' \notin B} \tilde{K}_N^*(d', t-1)}{\bigvee_{d' \in D} \tilde{K}_N^*(d', t-1)}$$

For each $d \in D$ the trajectory of extremal fuzzy process of the expert knowledge stream is monotone:

$$[\tilde{K}_{*N}(d, t); \tilde{K}_N^*(d, t)] \subseteq [\tilde{K}_{*N}(d, t-1); \tilde{K}_N^*(d, t-1)]$$

პროგნოზის ამოცანა ეცნ-ის ფაზი-მოდლისთვის

The modelled extremal fuzzy process of expert knowledge stream:

$$[\tilde{K}_{*N}(d, t); \tilde{K}_N^*(d, t)], t = s + 1, s + 2, \dots, \tau$$

cannot be used directly as prediction model in many cases.

We introduce a new additional fuzzy uncertainty which is the notion of prediction in the fuzzy time intervals:

let $[\tilde{K}_{*N}^0(d, t); \tilde{K}_N^{*0}(d, t)]$

be some continuous extremal fuzzy process as an approximation of discrete modelled process

$$[\tilde{K}_{*N}(d, t); \tilde{K}_N^*(d, t)]$$

As an example, it can be piecewise constant.



პროგნოზის ამოცანა ეცნ-ის ფაზი-მოდლისთვის

We can define continuous prediction regularized extremal fuzzy process in the fuzzy time interval $s \leq \tau_0 \leq \tau$

$$\tilde{Q}_{N^*}(d, \tau_0) = \int_{[s, \tau_0)}^* \tilde{K}_{*N}^0(d, t') \circ \tilde{g}_T^*(\cdot) =$$

$$= \int_{[s, +\infty)}^* [\tilde{K}_{*N}^0(d, t') \vee [s, \tau_0)] \circ \tilde{g}_T^*(\cdot);$$

$$\tilde{Q}_N^*(d, \tau_0) = \int_{[\tau_0, +\infty)}_* \tilde{K}_N^{0*}(d, t') \circ \tilde{g}_{T^*}(\cdot) =$$

$$= \int_{[s, +\infty)}_* [\tilde{K}_N^{0*}(d, t') \wedge [\tau_0, +\infty)] \circ \tilde{g}_{T^*}(\cdot),$$

where integrals are extended extremal integrals of Sugeno type.



პროგნოზის ამოცანა ეცნ-ის ფაზი-მოდლისთვის

This prediction regularized extremal fuzzy process is considered as a fuzzy-averaged process from the modelled stream of expert knowledge reflections in the predicted time interval $[s, \tau]$.

The main idea behind it is the following

The extremal possibilistic levels of decision $d \in D$ approximately at the moment τ_0 are represented by the pair

$$[\tilde{Q}_{N^*}(d, \tau_0); \tilde{Q}_N^*(d, \tau_0)]$$

If τ_0 is such minimal moment from $[s, \tau]$ that

$$|\tilde{Q}_{N^*}(d, \tau_0) - \tilde{Q}_N^*(d, \tau_0)| < \varepsilon$$



ოპტიმალური გაჩერება პროგნოზის ამოცანაში

then we can say that approximately at the moment τ_0 the possibilistic level of state is the interval

$$\left[\tilde{Q}_{N^*}(d, \tau_0); \tilde{Q}_N^*(d, \tau_0) \right]$$

which has ε accuracy.

Stopping of prediction time moment:

$$\tau^{opt} = \max(\tau_0^{d_1}, \tau_0^{d_2}, \dots, \tau_0^{d_n})$$

such that the intervals of possibility levels of d_1, d_2, \dots, d_n

states don't intersect.

ოპტიმალური გაჩერება პროგნოზის ამოცანაში

If , $\tau^{opt} \leq \tau$ this means that stopping has been performed in prediction interval, and we can sort the possibility levels and the decisions with highest level will become the prediction at approximately moment τ^{opt} .

ამოცანა: ექსპერტული შეფასებების დაზუსტების

პროცესის, როგორც ეცნ-ის ფაზი- მოდელირება

We construct an expert knowledge stream based on the temporalized procedure of decision making person's utilities.

The temporalized procedure is a process of construction of more précised expert evaluations.

We consider an utility model and the expert preferences- valuations (created by decision making person's utilities) ,

$\hat{U} : D \times \Omega \times T \rightarrow [0;1]$ where Ω is a set of all factors acting on the possible decisions D and $T = \{0,1, \dots, s\}$ is time structure.

The pair $[\hat{K}_*(d, t), \hat{K}^*(d, t)]$, $d \in D$ represents extremal expected utilities:

ეცნ-ის აგება სარგებლიანობის არაალბათური მოდელის გარემოში

- We construct information precision procedure as a temporalization of expert knowledge
- Objective function is chosen only on the basis of a non-specificity information measure $N(m_{t+1})$
- For estimations of focal probabilities we obtain a linear programming problem

In extremal trajectory - $[\hat{K}_*(d, t), \hat{K}^*(d, t)]$, $t = 0, 1, \dots, s$

the expert knowledge stream is condensed concerning the decisions, as from the point of view of imprecision as well as of uncertainty



ეცნ-ის აგება სარგებლიანობის არაალბათური მოდელის გარემოში

$$\hat{K}_*(d, t) = \sum_{A \in \mathfrak{A}_t} m_{t+1}(A) \hat{U}_*(d, A, t);$$

$$\hat{K}^*(d, t) = \sum_{A \in \mathfrak{A}_t} m_{t+1}(A) \hat{U}^*(d, A, t); \quad t = 0, 1, \dots$$

$$\begin{aligned} \hat{U}_*(d, A, t) &= \min_{\omega \in A} \hat{U}(d, \omega, t), \dots, \hat{U}^*(d, A, t) = \\ &= \max_{\omega \in A} \hat{U}(d, \omega, t), \end{aligned} \quad ($$

ეცნ-ის აგება სარგებლიანობის არაალბათური მოდელის გარემოში

$$\left\{ \begin{array}{l}
 \max_{\langle m_{t+1}(A_1^{t+1}), \dots, m_{t+1}(A_m^{t+1}) \rangle} \left\{ N(m_{t+1}) = \sum_{j=1}^m m_{t+1}(A_j^{t+1}) \cdot \log_2 |A_j^{t+1}| \right\}, \\
 m_{t+1}(A_j^{t+1}) \geq 0, \quad j = 1, 2, \dots, m; \quad \sum_{j=1}^m m_{t+1}(A_j^{t+1}) = 1, \\
 \mathfrak{R}_{t+1} \times \langle m_{t+1}(A_1^{t+1}), \dots, m_{t+1}(A_m^{t+1}) \rangle' \underset{(\leq)}{\geq} \langle m_t(A_1^t), \dots, m_t(A_k^t) \rangle', \\
 \sum_{j=1}^m \hat{U}_*(d_i, A_j^{t+1}, t+1) \cdot m_{t+1}(A_j^{t+1}) \geq \sum_{j=1}^k \hat{U}_*(d_i, A_t^j, t) \cdot m_t(A_j^t), \\
 \sum_{j=1}^m \hat{U}^*(d_i, A_t+1, t+1) \cdot m_{t+1}(A_j^{t+1}) \leq \sum_{j=1}^s \hat{U}^*(d_i, A_t^j, t) \cdot m_t(A_j^t), \\
 i = 1, 2, \dots, |D|,
 \end{array} \right.$$

რიცხვითი მაგალითი:

- მე მაქვს სამაგისტრო მოდულის „ინტელექტუალური ინფორმაციული სისტემი“ სტუდენტებთან მუშაობის გამოცდილება, რომელშიც სტუდენტები მუშაობენ ჯგუფურ პროექტებზე. სწავლება მოიცავს კომპლექსური სისტემებისა და პროცესების (კონტროლის მართვის, ინჟინერიისა და მენეჯმენტის და სხვ.) მოდულების შექმნის პროექტებს.
- საგნის გარემოში სტუდენტები ყოველთვის ქმნიან ასეთი პროექტის რეალიზაციის რამდენიმე წინასწარ ვერსიას...ამ დროს მე შეხებაა მაქვს რთულ პრობლემასთან - ავურჩიო სტუდენტებს პროექტის რეალიზაციის საუკეთესო ვერსია..
- პროექტის ვერსიების შესწავლის შემდეგ შესაძლებლობა მაქვს განვიხილო თითოეული სტუდენტის კომპეტენციის დონე პროექტის განხორციელებასთან დაკავშირებით და თითოეული სტუდენტი შევაფასო მისი სარგებლიანობის გარკვეული დონით პროექტის თითოეული მოცემული ვარიანტისთვის.

რიცხვითი მაგალითი:

- საჭირო იყო რომელიღაც ბიზნეს-ორგანიზაციის ფინანსური მდგომარეობის ხარისხის შესაფასებლად ინტ. სისტემის შექმნა..
- შემაჯავლი ინფორმაციას წარმოადგენს პარამეტრების ობიექტურ სტატისტიკური მონაცემები - როგორც ლინგვისტური ცვლადები, გაწერილი ფაზი-თერმებში. გვაქვს ერთი გამომაჯავლი ცვლადი-ორგანიზაციის ფინანს. მდგომარეობის ხარისხი, წარმოდგენილი ფაზი თერმებში.
უნდა აიგოს ფაზი-ლოჯიკ კონტროლერი = უნდა აიგოს ცოდნის ბაზა, რომელიც კონკრეტული შემაჯავლო ობიექტური მონაცემების შეტანის შემდეგ გამოავლენს ფინანსური მდგომარეობის ხარისხს.
- ფაზი-ლოჯიკ კონტროლერის, როგორც პროექტის ამოცანის სამი ვერსია იქნა წარმოდგენილი სტუდენტების მიერ.

რიცხვითი მაგალითი:

1. ფაზი-ლოჯიკ კონტროლერი აიგოს MatLab-ის Fuzzy-Logic ToolBox-ის გარემოში;
2. ფაზი-ლოჯიკ კონტროლერი აიგოს დაპროგრამების ენა C#-ის open source-ის შესაბამის გარემოში.
3. მართვის სისტემის ტანი, როგორც გადამრთველი შემავალ და გამომავალ მონაცემებს შორის, განვითარდეს არა ფაზი-წესებზე, არამედ ფაზი-ბინარული მიმართებების კომპოზიციებზე. შესაბამის პროგრამული უზრუნველყოფა შეიქმნას დაპროგრამების ენა C#-ის გარემოში.

რიცხვითი მაგალითი:

Thus three versions of project have been created $D = \{d_1, d_2, d_3\}$ in which 7 students were participating, say

$$\Omega = \{\omega_1, \omega_2, \omega_3, \omega_4, \omega_5, \omega_6, \omega_7\}$$

All seven of them participated in development of all three versions, but in different sub-groups.

They created four groups (in future called focal elements):

რიცხვითი მაგალითი:

- A_1 - the group for problem detalization, gathering of input data, its initial processing and construction of conceptual model;
- A_2 - the group for conceptual model validation and software development;
- A_3 - the group for software verification and testing;
- A_4 - the management group.

The students were divided into the subgroups in the following way: $A_1 = \{\omega_1, \omega_3, \omega_4\}$,

$A_2 = \{\omega_2, \omega_3, \omega_5, \omega_6\}$, $A_3 = \{\omega_1, \omega_2, \omega_6, \omega_7\}$,

$A_4 = \{\omega_4, \omega_6, \omega_7\}$.

რიცხვითი მაგალითი:

1. After some time the students presented all three variants of the project .

2. I had to choose the best one with the objective of optimal realization of the problem.

3. I had to evaluate the utilities of students concerning each version. So I had to study the projects in detail.

4. Also I had to consider students' competences and knowledge in given topics, the quality and reliability of the realization of projects' variants, the ability to work in groups, etc.



მაგალითი: დაზუსტების

(ტემპორალიზაციის) საწყისი ბიჯი

- The first estimations were made just according the brief overview of projects:

Table 1. The utility evaluations on the initial step of temporalization – \hat{U}_0 .

D	Ω						
	ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	ω_7
d_1	0.4	0.7	0.6	0.8	0.5	0.4	0.6
d_2	0.6	0.8	0.5	0.9	0.6	0.8	0.7
d_3	0.3	0.9	0.4	0.7	0.3	0.7	0.6

- The comparison of variants and selection of best one by their utilities is impossible.

Let's use temporalization

•

•

დაზუსტების (ტემპორალიზაციის)

საწყისი ბიჯი

Table 2. Extremal utilities on initial step of temporalization – $\langle \hat{U}_{0*}, \hat{U}_0^* \rangle$

<i>D</i>	\mathfrak{S}			
	<i>A</i> ₁	<i>A</i> ₂	<i>A</i> ₃	<i>A</i> ₄
<i>d</i> ₁	[0.4; 0.8]	[0.4; 0.7]	[0.4; 0.7]	[0.6; 0.7]
<i>d</i> ₂	[0.5; 0.9]	[0.5; 0.8]	[0.6; 0.8]	[0.7; 0.9]
<i>d</i> ₃	[0.3; 0.7]	[0.3; 0.7]	[0.3; 0.9]	[0.6; 0.7]

- On initial step let us suppose, that focal probabilities have uniform distribution

დაზუსტების (ტემპორალიზაციის) საწყისი

ბიჯი

Table 3. Extremal expected utilities on initial step of temporalization - $[\hat{K}_*(\cdot, 0); \hat{K}^*(\cdot, 0)]$

d_1	d_2	d_3
[0.45, 0.725]	[0.575, 0.850]	[0.375, 0.800]

- it is impossible to choose the best decision among d_s , which would be natural, because their expected utility intervals intersect.

დაზუსტების (ტემპორალიზაციის)

პირველი ბიჯი

- Let us move on the first step of temporalization.

On the first step of temporalization we suppose, that the table of utilities (Table 1) doesn't change. Then the numerical solution of the mathematical programming problem gives us

the results: $m_1(A_1^1) = 0.14$; $m_1(A_2^1) = 0.16$; $m_1(A_3^1) = 0.33$

$$m_1(A_4^1) = 0.37.$$

Table 4. Extremal expected utilities on the first step of temporalization - $[\hat{K}^*(\cdot, 1); \hat{K}^*(\cdot, 1)]$

d_1	d_2	d_3
[0.47, 0.715]	[0.605, 0.850]	[0.405, 0.800]

დაზუსტების (ტემპორალიზაციის)

მეორე ბიჯი

We continue the temporalization: After obtaining additional information on the competences and professional knowledge of the students, on the second step of temporalization the table of utilities changed in the following way:

Table 5. The utility evaluations on the second step of temporalization $-\hat{u}_2$.

D	Ω						
	ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	ω_7
d_1	0.45	0.75	0.55	0.65	0.6	0.5	0.55
d_2	0.65	0.85	0.85	0.55	0.7	0.75	0.7
d_3	0.4	0.85	0.45	0.65	0.7	0.75	0.6

დაზუსტების (ტემპორალიზაციის)

მეორე ბიჯი

Table 6. Extremal utilities on the second step of temporalization – $\langle \hat{U}_{2*}, \hat{U}_2^* \rangle$

	\mathfrak{S}			
D	A_1	A_2	A_3	A_4
d_1	[0.45; 0.65]	[0.5; 0.75]	[0.45; 0.75]	[0.5; 0.65]
d_2	[0.55; 0.85]	[0.7; 0.85]	[0.65; 0.85]	[0.55; 0.75]
d_3	[0.4; 0.65]	[0.45; 0.85]	[0.4; 0.85]	[0.6; 0.75]

On this step we obtain $m_3(A_1^2) = 0.14$;

$$m_3(A_2^2) = 0.16; \quad m_3(A_3^2) = 0.40; \quad m_3(A_4^2) = 0.30.$$

დაზუსტების (ტემპორალიზაციის)

მეორე ბიჯი

Table 7. Extremal expected utilities on the second step of temporalization – $[\hat{K}_*(\cdot, 2); \hat{K}^*(\cdot, 2)]$

d_1	d_2	d_3
[0.475, 0.700]	[0.607, 0.815]	[0.4775, 0.785]

- The process of précising the information enabled us to continue the temporalization until the 7-th step ($s = 6$). The trajectory of précising the knowledge streams is given in the Table 9.

დაზუსტების (ტემპორალიზაციის)

პროცესის (ეცნ-ის) აგების შედეგები

Table 9. The extremal fuzzy process of expert knowledge precision

	d_1	d_2	d_3
$[\hat{K}_*(\cdot, 0); \hat{K}^*(\cdot, 0)]$	[0.450, 0.725]	[0.575, 0.850]	[0.375, 0.800]
$[\hat{K}_*(\cdot, 1); \hat{K}^*(\cdot, 1)]$	[0.47, 0.715]	[0.605, 0.850]	[0.405, 0.800]
$[\hat{K}_*(\cdot, 2); \hat{K}^*(\cdot, 2)]$	[0.475, 0.700]	[0.607, 0.815]	[0.4775, 0.785]
$[\hat{K}_*(\cdot, 3); \hat{K}^*(\cdot, 3)]$	[0.485, 0.700]	[0.617, 0.815]	[0.485, 0.748]
$[\hat{K}_*(\cdot, 4); \hat{K}^*(\cdot, 4)]$	[0.485, 0.689]	[0.635, 0.779]	[0.504, 0.693]
$[\hat{K}_*(\cdot, 5); \hat{K}^*(\cdot, 5)]$	[0.486, 0.563]	[0.672, 0.743]	[0.517, 0.641]
$[\hat{K}_*(\cdot, 6); \hat{K}^*(\cdot, 6)]$	[0.486, 0.532]	[0.692, 0.725]	[0.524, 0.602]

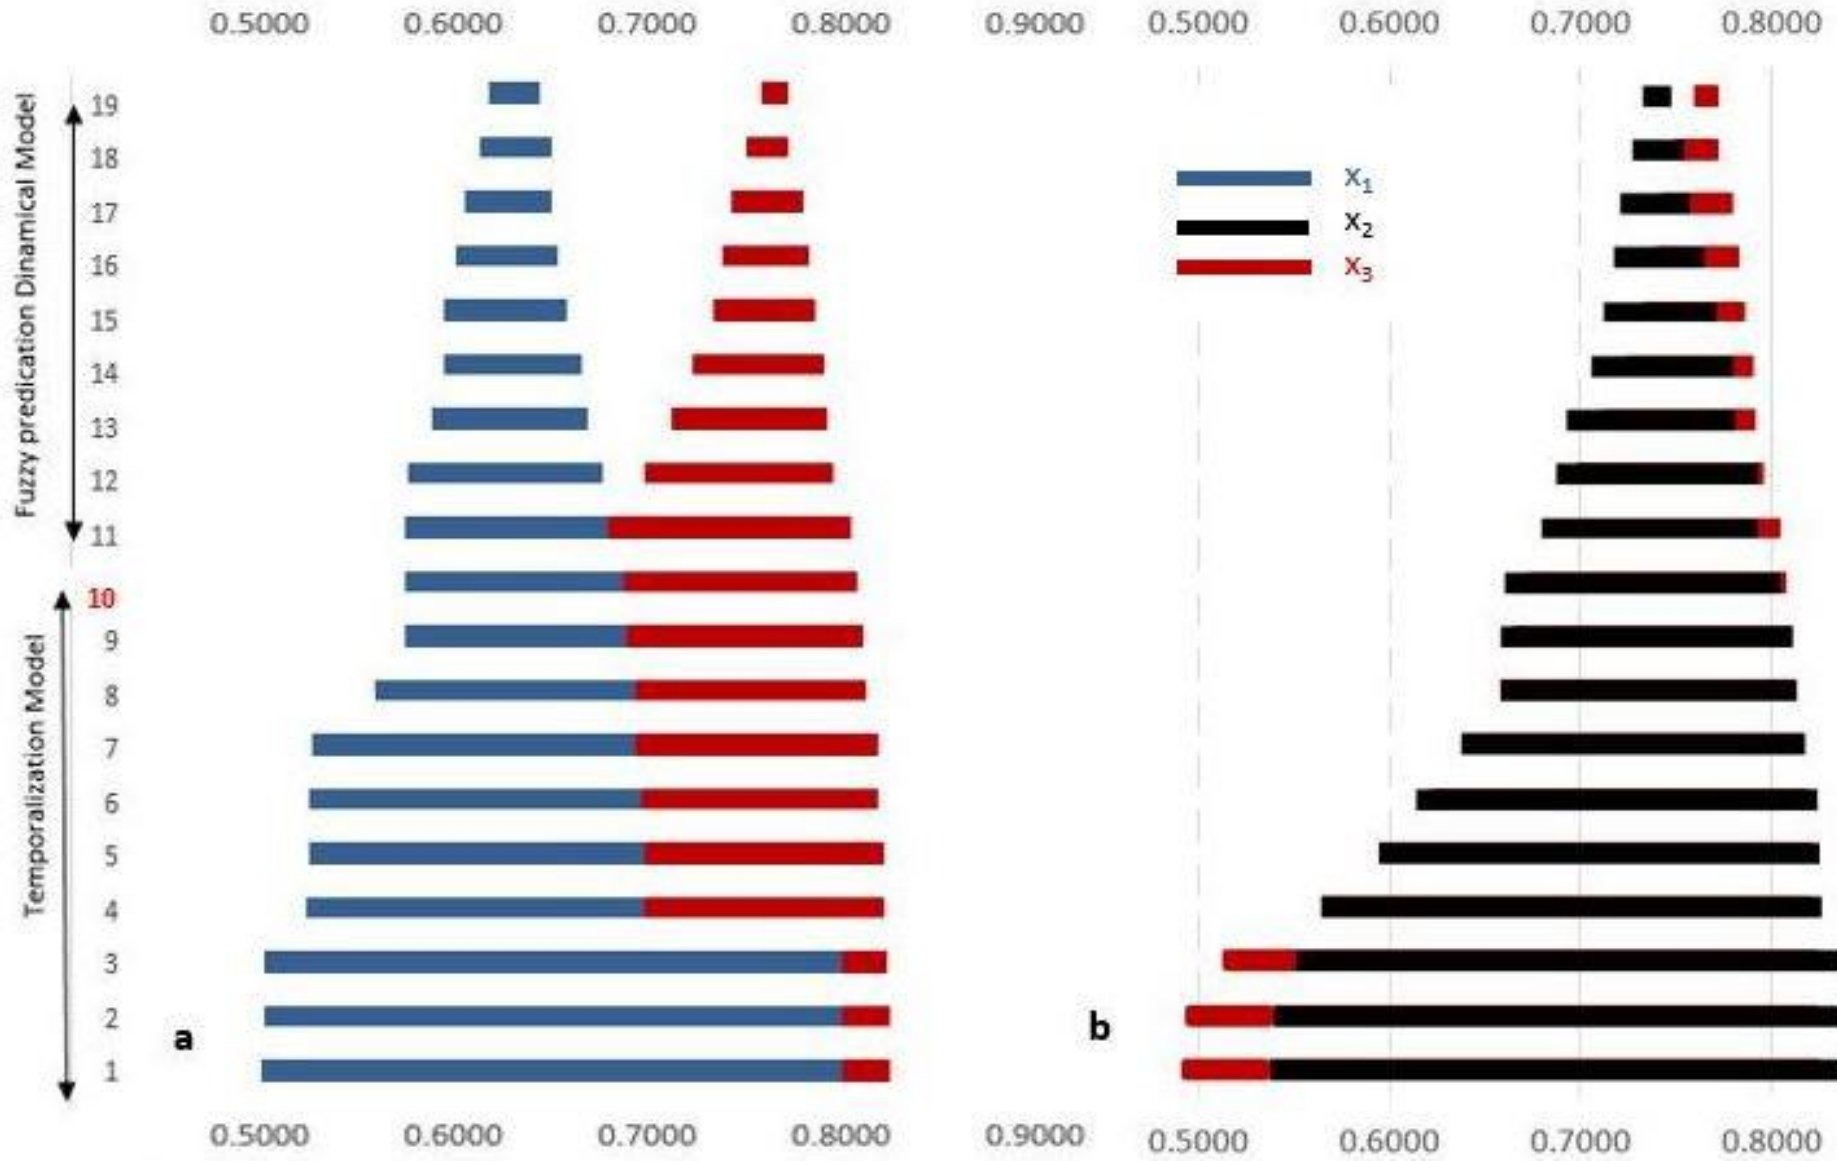
პროგნოზის ამოცანის შედეგები

- Using the prediction problem's solution scheme (problem II) we obtain the results presented in Table 10. The Table 10 shows modeling and prediction results (the parameters are $\varepsilon = 10^{-2}$; $s = 6$; $\tau^{opt} = 19$)
- For time period [7; 19] we construct prediction continuous extremal fuzzy process .
- More precisely, predicted optimal possibilistic distribution for approximately time moment $\tau_0 = 19$

Table 10. The modelled extremal fuzzy process of expert knowledge precision

Modeling step	$[\tilde{K}_{*N}(d, t), \tilde{K}_N^*(d, t)]$	d_1	d_2	d_3
Prediction time period				
7	$[\hat{K}_{*N}(\cdot, 7), \hat{K}_N^*(\cdot, 7)]$	[0.491, 0.551]	[0.670, 0.723]	[0.525, 0.613]
8	$[\hat{K}_{*N}(\cdot, 8), \hat{K}_N^*(\cdot, 8)]$	[0.494, 0.549]	[0.674, 0.719]	[0.528, 0.607]
9	$[\hat{K}_{*N}(\cdot, 9), \hat{K}_N^*(\cdot, 9)]$	[0.497, 0.534]	[0.679, 0.715]	[0.532, 0.602]
10	$[\hat{K}_{*N}(\cdot, 10), \hat{K}_N^*(\cdot, 10)]$	[0.499, 0.521]	[0.682, 0.711]	[0.535, 0.598]
11	$[\hat{K}_{*N}(\cdot, 11), \hat{K}_N^*(\cdot, 11)]$	[0.502, 0.519]	[0.687, 0.709]	[0.541, 0.591]
12	$[\hat{K}_{*N}(\cdot, 12), \hat{K}_N^*(\cdot, 12)]$	[0.508, 0.518]	[0.691, 0.705]	[0.544, 0.587]
13	$[\hat{K}_{*N}(\cdot, 13), \hat{K}_N^*(\cdot, 13)]$	[0.511, 0.516]	[0.693, 0.704]	[0.548, 0.582]
14	$[\hat{K}_{*N}(\cdot, 14), \hat{K}_N^*(\cdot, 14)]$	[0.513, 0.515]	[0.697, 0.704]	[0.550, 0.576]
15	$[\hat{K}_{*N}(\cdot, 15), \hat{K}_N^*(\cdot, 15)]$	0.51	[0.698, 0.703]	[0.553, 0.573]
16	$[\hat{K}_{*N}(\cdot, 16), \hat{K}_N^*(\cdot, 16)]$		[0.701, 0.703]	[0.556, 0.569]
17	$[\hat{K}_{*N}(\cdot, 17), \hat{K}_N^*(\cdot, 17)]$		0.70	[0.557, 0.568]
18	$[\hat{K}_{*N}(\cdot, 18), \hat{K}_N^*(\cdot, 18)]$			[0.561, 0.564]
19	$[\hat{K}_{*N}(\cdot, 19), \hat{K}_N^*(\cdot, 19)]$			0.56

Diagram of the prediction regularization



პროგნოზის ამოცანის შედეგები

- ცხადია პროექტის მეორე ვარიანტი, როგორც ოპტიმალური ვარიანტი, იქნა მხარდაჭერილი ჩემს მიერ დაახლოებით $[0.701 \div 0.703]$ შესაძლებლობის დონით

მადლობა ყურადღებებისთვის