

Adaptív dinamikus szegmentálás idősorok indexeléséhez

IPM-08irAREAE kurzus cikkfeldolgozás

Balassi Márton¹
Englert Péter¹
Tömösy Péter¹

¹Eötvös Loránd Tudományegyetem – Informatikai Kar

2013. november 20.



Tartalom

Bevezetés

Módszerek

Eredmények

Összefoglalás



Tartalom

Bevezetés


Módszerek

Eredmények

Összefoglalás



Feladat




Idősorok hatékony szegmentálása

- ▶ Adatsorok hasonlósági keresése
- ▶ Dinamikus, adaptív indexelés
- ▶ Empirikus eredmények



Feladat




Idősorok hatékony szegmentálása

- ▶ Adatsorok hasonlósági keresése
- ▶ Dinamikus, adaptív indexelés
- ▶ Empirikus eredmények



Feladat



Idősorok hatékony szegmentálása

- ▶ Adatsorok hasonlósági keresése
- ▶ Dinamikus, adaptív indexelés
- ▶ Empirikus eredmények



Motiváció

Széles alkalmazási terület

- ▶ Orvosi alkalmazás
- ▶ Tőzsde
- ▶ Szensorhálózatok
- ▶ ...



Motiváció

Széles alkalmazási terület

- ▶ Orvosi alkalmazás
- ▶ Tőzsde
- ▶ Szenzorhálózatok
- ▶ ...



Motiváció

Széles alkalmazási terület

- ▶ Orvosi alkalmazás
- ▶ Tőzsde
- ▶ Szenzorhálózatok
- ▶ ...



Motiváció

Széles alkalmazási terület

- ▶ Orvosi alkalmazás
- ▶ Tőzsde
- ▶ Szenzorhálózatok
- ▶ ...



Motiváció

Széles alkalmazási terület

- ▶ Orvosi alkalmazás
- ▶ Tőzsde
- ▶ Szenzorhálózatok
- ▶ ...

Javítási ötlet

- ▶ Eddig globálisan indexelték az idősorhalmazokat
- ▶ Nem használtak felülről korlátozó függvényeket



Motiváció

Széles alkalmazási terület

- ▶ Orvosi alkalmazás
- ▶ Tőzsde
- ▶ Szenzorhálózatok
- ▶ ...

Javítási ötlet

- ▶ Eddig globálisan indexelték az idősorhalmazokat
- ▶ Nem használtak felülről korlátozó függvényeket



Definíciók

Idősor

A továbbiakban legyen adott n pozitív egész szám, valamint $X = (x_1, x_2, \dots, x_n)$ és $Y = (y_1, y_2, \dots, y_n)$ n hosszú, valós számokból álló idősorok. Ezek halmaza legyen \mathcal{TS} .



Definíciók

Idősor

A továbbiakban legyen adott n pozitív egész szám, valamint $X = (x_1, x_2, \dots, x_n)$ és $Y = (y_1, y_2, \dots, y_n)$ n hosszú, valós számokból álló idősorok. Ezek halmaza legyen \mathcal{TS} .

Távolság

X és Y euklideszi távolsága $D(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$.



Definíciók

Távolság

X és Y euklideszi távolsága $D(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$.

Teljes illesztés

Legyen adott $Q \in \mathcal{TS}$ és $0 < \epsilon \in \mathbb{R}$. Keressük azokat az S idősorokat, melyekre $D(Q, S) \leq \epsilon$. Ha a hasonlósági mérték az euklideszi távolság, az idősorok pedig azonos hosszúságúak, ezt teljes illesztésnek nevezzük.



Korábbi eredmények

Alulról korlátozó dimenziócsökkentés

Létezik $D_{LB}(\cdot, \cdot)$ függvény, melyre ha $S_i (i \in \{1, 2\})$ idősor reprezentációja $\tilde{S}_i (i \in \{1, 2\})$, akkor $D_{LB}(\tilde{S}_1, \tilde{S}_2) \leq D(S_1, S_2)$.



Korábbi eredmények

Alulról korlátozó dimenziócsökkentés

Létezik $D_{LB}(\cdot, \cdot)$ függvény, melyre ha $S_i (i \in \{1, 2\})$ idősor reprezentációja $\tilde{S}_i (i \in \{1, 2\})$, akkor $D_{LB}(\tilde{S}_1, \tilde{S}_2) \leq D(S_1, S_2)$.
Ekkor ha $D_{LB}(\tilde{Q}, \tilde{S}) > \epsilon$, akkor az S által reprezentált idősorokat már nem kell vizsgálnunk, ugyanis azok tényleges távolsága Q -tól biztos, hogy ϵ -nál nagyobb.



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



Korábbi eredmények

Felhasznált módszerek

- ▶ Dimenziócsökkentésre:
 - ▶ diszkrét Fourier-transzformációt
 - ▶ szinguláris felbontás
 - ▶ diszkrét wavelet transzformáció
 - ▶ ...
- ▶ Indexelésre:
 - ▶ R-fa
 - ▶ SAX
 - ▶ iSAX



A cikk fő eredményei

Eredmények

- ▶ **Felülről korlátozó dimenziócsökkentés**
- ▶ DSTree
- ▶ Hisztogramkészítés



A cikk fő eredményei

Eredmények

- ▶ Felülről korlátozó dimenziócsökkentés
- ▶ DSTree
- ▶ Hisztogramkészítés



A cikk fő eredményei

Eredmények

- ▶ Felülről korlátozó dimenziócsökkentés
- ▶ DSTree
- ▶ Hisztogramkészítés



Tartalom

Bevezetés

Módszerek

Eredmények

Összefoglalás



Adaptív szakaszonként konstans approximáció

APCA

Egy X idősort (X_1, X_2, \dots, X_m) szegmenseire bontjuk, ahol $m \leq n$ és $\forall j \in \{1, \dots, m\} : X_j = (x_{r_{j-1}+1}, \dots, x_{r_j})$ valamely $0 = r_0 < r_1 < \dots < r_m = n$ indexsorozatra.



Adaptív szakaszonként konstans approximáció

APCA

Egy X idősort (X_1, X_2, \dots, X_m) szegmenseire bontjuk, ahol $m \leq n$ és $\forall j \in \{1, \dots, m\} : X_j = (x_{r_{j-1}+1}, \dots, x_{r_j})$ valamely $0 = r_0 < r_1 < \dots < r_m = n$ indexsorozatra.

Egy X_j szegmens reprezentációja a (μ_j, r_j) pár lesz, ahol

$$\mu_j = \frac{\sum_{k=r_{j-1}+1}^{r_j} s_k}{r_j - r_{j-1}}$$
 a szegmens értékeinek átlaga. X közelítő reprezentációja tehát $\tilde{X} = ((\mu_1, r_1), \dots, (\mu_m, r_m))$.



Adaptív szakaszonként konstans approximáció

Illeszkedés

Azt mondjuk, hogy \tilde{X} és \tilde{Y} APCA reprezentációk illeszkednek, ha az előző bekezdés jelöléseivel az m és r_0, \dots, r_m értékeik megegyeznek, vagyis:

$$\tilde{X} = ((\mu_1^X, r_1), \dots, (\mu_m^X, r_m)),$$

$$\tilde{Y} = ((\mu_1^Y, r_1), \dots, (\mu_m^Y, r_m)).$$



Adaptív szakaszonként konstans approximáció

Lemma

Adott két egyforma hosszú idősor, X és Y , valamint illeszkedő APCA reprezentációik, $\tilde{X} = ((\mu_1^X, r_1), \dots, (\mu_m^X, r_m))$ és $\tilde{Y} = ((\mu_1^Y, r_1), \dots, (\mu_m^Y, r_m))$.



Adaptív szakaszonként konstans approximáció

Lemma

Adott két egyforma hosszú idősor, X és Y , valamint illeszkedő APCA reprezentációik, $\tilde{X} = ((\mu_1^X, r_1), \dots, (\mu_m^X, r_m))$ és $\tilde{Y} = ((\mu_1^Y, r_1), \dots, (\mu_m^Y, r_m))$.

Ekkor:

$$D(X, Y) \geq \sqrt{\sum_{i=1}^m (r_i - r_{i-1}) (\mu_i^X - \mu_i^Y)^2}$$



Bővített adaptív szakaszonként konstans approximáció

EAPCA

A szegmensek reprezentációját az értékek szórásával egészíti ki, és ennek segítségével egy pontosabb alsó korlátot, valamint egy felső korlátot is definiál.



Bővített adaptív szakaszonként konstans approximáció

EAPCA

A szegmensek reprezentációját az értékek szórásával egészíti ki, és ennek segítségével egy pontosabb alsó korlátot, valamint egy felső korlátot is definiál.

$$\tilde{X} = ((\mu_1, \sigma_1, r_1), \dots, (\mu_m, \sigma_m, r_m)), \text{ ahol}$$

$$\sigma_i = \sqrt{\frac{\sum_{j=r_{i-1}+1}^{r_i} s_j^2}{r_i - r_{i-1}} - \left(\frac{\sum_{j=r_{i-1}+1}^{r_i} s_j}{r_i - r_{i-1}}\right)^2}$$

értékek a reprezentált szegmens értékeinek szórása.



Bővített adaptív szakaszonként konstans approximáció

Tétel

Adott két egyforma hosszú idősor, X és Y , valamint illeszkedő EAPCA reprezentációik, $\tilde{X} = ((\mu_1^X, \sigma_1^X, r_1), \dots, (\mu_m^X, \sigma_m^X, r_m))$ és $\tilde{Y} = ((\mu_1^Y, \sigma_1^Y, r_1), \dots, (\mu_m^Y, \sigma_m^Y, r_m))$.



Bővített adaptív szakaszonként konstans approximáció

Tétel

Adott két egyforma hosszú idősor, X és Y , valamint illeszkedő EAPCA reprezentációik, $\tilde{X} = ((\mu_1^X, \sigma_1^X, r_1), \dots, (\mu_m^X, \sigma_m^X, r_m))$ és $\tilde{Y} = ((\mu_1^Y, \sigma_1^Y, r_1), \dots, (\mu_m^Y, \sigma_m^Y, r_m))$. Ekkor:

$$D(X, Y) \geq \sqrt{\sum_{i=1}^m (r_i - r_{i-1}) [(\mu_i^X - \mu_i^Y)^2 + (\sigma_i^X - \sigma_i^Y)^2]},$$

$$D(X, Y) \leq \sqrt{\sum_{i=1}^m (r_i - r_{i-1}) [(\mu_i^X - \mu_i^Y)^2 + (\sigma_i^X + \sigma_i^Y)^2]}.$$



Korlátok idősorok halmazaitól vett távolságra

Feladat

X idősor és Y_1, \dots, Y_l egyforma hosszú idősorok esetén a $\min_{1 \leq j \leq l} D(X, Y_j)$ távolságot szeretnénk alulról becsülni.



Korlátok idősorok halmazaitól vett távolságra

Jelölés

Legyen X, Y_1, \dots, Y_l mind egyforma hosszú, továbbá legyenek

$$\tilde{X} = ((\mu_1^X, \sigma_1^X, r_1), \dots, (\mu_m^X, \sigma_m^X, r_m)),$$

$$\tilde{Y}_1 = ((\mu_1^{Y_1}, \sigma_1^{Y_1}, r_1), \dots, (\mu_m^{Y_1}, \sigma_m^{Y_1}, r_m)),$$

...

$$\tilde{Y}_l = ((\mu_1^{Y_l}, \sigma_1^{Y_l}, r_1), \dots, (\mu_m^{Y_l}, \sigma_m^{Y_l}, r_m))$$

az X, Y_1, \dots, Y_l idősorok illeszkedő EAPCA reprezentációi.



Korlátok idősorok halmazaitól vett távolságra

Jelölés

Jelölje az $\tilde{Y}_1, \dots, \tilde{Y}_l$ halmazban i . szegmens minimális és maximális átlagát $\mu_i^{min} = \min_{1 \leq j \leq l} \mu_i^{Y_j}$ és $\mu_i^{max} = \max_{1 \leq j \leq l} \mu_i^{Y_j}$, szórását pedig $\sigma_i^{min} = \min_{1 \leq j \leq l} \sigma_i^{Y_j}$ és $\sigma_i^{max} = \max_{1 \leq j \leq l} \sigma_i^{Y_j}$.



Korlátok idősorok halmazaitól vett távolságra

Tétel

Adott X, Y_1, \dots, Y_l egyforma hosszú idősorok és illeszkedő $\tilde{X}, \tilde{Y}_1, \dots, \tilde{Y}_l$ EAPCA reprezentációik. Ekkor:



Korlátok idősorok halmazaitól vett távolságra

Tétel

$$\min_{1 \leq j \leq l} D(X, Y_j) \geq \sqrt{\sum_{i=1}^m (r_i - r_{i-1})(LB_i^\mu + LB_i^\sigma)^2},$$
$$\max_{1 \leq j \leq l} D(X, Y_j) \leq \sqrt{\sum_{i=1}^m (r_i - r_{i-1})(UB_i^\mu + UB_i^\sigma)^2}.$$



Korlátok idősorok halmazaitól vett távolságra

Tétel

$$\min_{1 \leq j \leq l} D(X, Y_j) \geq \sqrt{\sum_{i=1}^m (r_i - r_{i-1})(LB_i^\mu + LB_i^\sigma)^2},$$

$$\max_{1 \leq j \leq l} D(X, Y_j) \leq \sqrt{\sum_{i=1}^m (r_i - r_{i-1})(UB_i^\mu + UB_i^\sigma)^2}.$$

Ahol $LB_i^\mu, LB_i^\sigma, UB_i^\mu, UB_i^\sigma$ elemi függvényei a $\{\mu_i, \sigma_i\}^{\{min; max; X\}}$ halmaz elemeinek.



Korlátok idősorok halmazaitól vett távolságra

Következmény

Ha az illeszkedő EAPCA reprezentációval adott idősorok halmazától vett távolságot szeretnénk alulról becsülni, ahhoz elég a szegmensek átlagainak és szórásainak minimumát és maximumát számon tartanunk.



DSTree

Reprezentáció

Az EAPCA szegmenseket meghatározza jobb végpontjuk, vagyis (r_1, \dots, r_m) , ahol $0 < r_1 < r_2 < \dots < r_m = n$.



DSTree

Reprezentáció

Az EAPCA szegmenseket meghatározza jobb végpontjuk, vagyis (r_1, \dots, r_m) , ahol $0 < r_1 < r_2 < \dots < r_m = n$.

Finomítás

Adott $SG_1 = (r_1, \dots, r_m)$ és $SG_2 = (r'_1, \dots, r'_{m'})$ szegmentálásokra SG_2 egylépéses finomítása SG_1 -nek, ha $m' = m + 1$, és $\exists i_0 : 1 \leq i_0 < m$, hogy $1 \leq i \leq i_0$ esetén $r_i = r'_i$, $i_0 < i$ esetén pedig $r_i = r'_{i+1}$. Jelölése: $SG_1 \prec^1 SG_2$. A reláció tranzitív lezártja a finomítás reláció.



DSTree

Konstrukció

Bináris fával dolgozunk, egy csúcs a részfájába tartozó idősorok egy indexe.



DSTree

Konstrukció

Bináris fával dolgozunk, egy csúcs a részfájába tartozó idősorok egy indexe. Minden csúcsban tároljuk a következő információkat:

- ▶ A csúcs által meghatározott részfában található idősorok C számát.
- ▶ Az $SG = (r_1, \dots, r_m)$ szegmentálását a csúcs által indexelt idősoroknak.
- ▶ A felső és alsó korlát számításához felhasználható aggregált $Z = (z_1, \dots, z_m)$ információt, ahol $z_i = (\mu_i^{\min}, \mu_i^{\max}, \sigma_i^{\min}, \sigma_i^{\max})$.



DSTree

Konstrukció

Bináris fával dolgozunk, egy csúcs a részfájába tartozó idősorok egy indexe. Minden csúcsban tároljuk a következő információkat:

- ▶ A csúcs által meghatározott részfában található idősorok C számát.
- ▶ Az $SG = (r_1, \dots, r_m)$ szegmentálását a csúcs által indexelt idősoroknak.
- ▶ A felső és alsó korlát számításához felhasználható aggregált $Z = (z_1, \dots, z_m)$ információt, ahol $z_i = (\mu_i^{\min}, \mu_i^{\max}, \sigma_i^{\min}, \sigma_i^{\max})$.



DSTree

Konstrukció

Bináris fával dolgozunk, egy csúcs a részfájába tartozó idősorok egy indexe. Minden csúcsban tároljuk a következő információkat:

- ▶ A csúcs által meghatározott részfában található idősorok C számát.
- ▶ Az $SG = (r_1, \dots, r_m)$ szegmentálását a csúcs által indexelt idősoroknak.
- ▶ A felső és alsó korlát számításához felhasználható aggregált $Z = (z_1, \dots, z_m)$ információt, ahol $z_i = (\mu_i^{min}, \mu_i^{max}, \sigma_i^{min}, \sigma_i^{max})$.



DSTree

Konstrukció

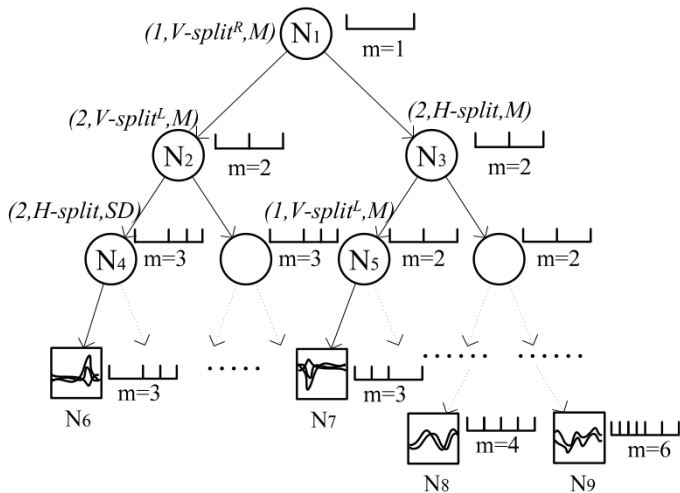
Bináris fával dolgozunk, egy csúcs a részfájába tartozó idősorok egy indexe. Minden csúcsban tároljuk a következő információkat:

- ▶ A csúcs által meghatározott részfában található idősorok C számát.
- ▶ Az $SG = (r_1, \dots, r_m)$ szegmentálását a csúcs által indexelt idősoroknak.
- ▶ A felső és alsó korlát számításához felhasználható aggregált $Z = (z_1, \dots, z_m)$ információt, ahol $z_i = (\mu_i^{min}, \mu_i^{max}, \sigma_i^{min}, \sigma_i^{max})$.

A levelek tárolnak egy mutatót egy legfeljebb ψ (levélkapacitás) idősort tároló fájlra, a belső csúcsok tárolják a hasítási stratégiát.



Példa DSTree-re



Beszúrás DSTree-be

Algorithm 1 $N.Insert(X)$: N is a node, X is a time series

```

1: update  $Z$  in node  $N$  according to  $X$ ;
2: if  $N$  is a leaf node then
3:   if  $C < \psi$  then                                ▷  $N$  has space to hold  $X$ 
4:     Append  $X$  to data file pointed by  $N$ ,  $C = C + 1$ ;
5:   else                                             ▷  $C == \psi$ , no space in  $N$  to hold  $X$ 
6:     Append  $X$  to data file pointed by  $N$ ,  $C = C + 1$ ;
7:      $SP = BestSplit()$ ;
8:     Create two children nodes for  $N$ ;
9:     for each time series  $Y$  in  $N$  do
10:        $N' = N.routeToChild(Y, SP)$ ;  $N'.insert(Y)$ ;
11:     end for
12:   end if
13: else
14:    $N' = N.routeToChild(X, SP)$ ;  $N'.insert(X)$ ;
15: end if

```



Hasítási stratégiák

Vízszintes hasítás (H-split)

Függőleges hasítás (V-split)



Hasítási stratégiák

Vízszintes hasítás (H-split)

A szegmentálás nem változik, az utódok szegmentálása ugyanaz marad, csak kétfelé osztjuk őket.

Függőleges hasítás (V-split)

A szegmentálás finomodik, a szülő csúcs szegmentálásának ugyanazt az egylépéses finomítását fogja tartalmazni mindkét utód.



Műveletek

Hasonlósági keresés

Hisztogram készítés



Műveletek

Hasonlósági keresés

A heurisztikus hasonlósági keresés a beszúrás mintájára megnézi, hogy melyik levélbe kerülne a lekérdezés Q idősora, majd az ebben a levélben tárolt minden idősorra kiszámítja annak Q -tól vett távolságát, és visszaadja a legközelebbit.

Hisztogram készítés

A csúcokban a Q -tól vett távolságra számított alsó és felső korlát, valamint a csúcs által indexelt idősorok száma alapján, azok összesítésével tudunk becslést adni adott távolság-intervallumon belül levő idősorok számára.



Tartalom

Bevezetés

Módszerek

Eredmények

Összefoglalás



Tesztspecifikáció

Alternatív módszerek

- ▶ Piecewise Aggregate Approximation (PAA) & R-fa
- ▶ iSAX2.0



Tesztspecifikáció

Alternatív módszerek

- ▶ Piecewise Aggregate Approximation (PAA) & R-fa
- ▶ iSAX2.0



Tesztspecifikáció

Alternatív módszerek

- ▶ Piecewise Aggregate Approximation (PAA) & R-fa
- ▶ iSAX2.0

Tesztadatok

- ▶ Szintetikus
- ▶ Valódi



Tesztspecifikáció

Alternatív módszerek

- ▶ Piecewise Aggregate Approximation (PAA) & R-fa
- ▶ iSAX2.0

Tesztadatok

- ▶ Szintetikus
- ▶ Valódi



Tesztspecifikáció

Inputgenerálás

- ▶ Véletlen bolyongás, a $[-5, 5]$ -ből egyenletesen véletlen kezdőponttal, valamint a $[0, 2]$ -ből egyenletesen véletlen lépéshosszal.
- ▶ Normális eloszlással generálódnak az idősor pontjai. A középpont a $[-5, 5]$ -ből, szórása pedig a $[0, 2]$ -ből kerül egyenletesen véletlenül kiválasztásra.
- ▶ Az előző módszerrel generálunk legalább 3, legfeljebb 10 idősort, majd ezeket konkatenáljuk.
- ▶ Több szinuszfüggvény összekeveréséből mintavételezéssel. A függvények periódusa a $[2, 10]$ -ből, amplitúdója a $[2, 10]$ -ből, átlaga pedig a $[-5, 5]$ -ből egyenletesen véletlen.



Tesztspecifikáció

Inputgenerálás

- ▶ Véletlen bolyongás, a $[-5, 5]$ -ből egyenletesen véletlen kezdőponttal, valamint a $[0, 2]$ -ből egyenletesen véletlen lépéshosszal.
- ▶ Normális eloszlással generálódnak az idősor pontjai. A középpont a $[-5, 5]$ -ből, szórása pedig a $[0, 2]$ -ből kerül egyenletesen véletlenül kiválasztásra.
- ▶ Az előző módszerrel generálunk legalább 3, legfeljebb 10 idősort, majd ezeket konkatenáljuk.
- ▶ Több szinuszfüggvény összekeveréséből mintavételezéssel. A függvények periódusa a $[2, 10]$ -ből, amplitúdója a $[2, 10]$ -ből, átlaga pedig a $[-5, 5]$ -ből egyenletesen véletlen.



Tesztspecifikáció

Inputgenerálás

- ▶ Véletlen bolyongás, a $[-5, 5]$ -ből egyenletesen véletlen kezdőponttal, valamint a $[0, 2]$ -ből egyenletesen véletlen lépéshosszal.
- ▶ Normális eloszlással generálódnak az idősor pontjai. A középpont a $[-5, 5]$ -ből, szórása pedig a $[0, 2]$ -ből kerül egyenletesen véletlenül kiválasztásra.
- ▶ Az előző módszerrel generálunk legalább 3, legfeljebb 10 idősort, majd ezeket konkatenáljuk.
- ▶ Több szinuszfüggvény összekeveréséből mintavételezéssel. A függvények periódusa a $[2, 10]$ -ből, amplitúdója a $[2, 10]$ -ből, átlaga pedig a $[-5, 5]$ -ből egyenletesen véletlen.




Tesztspecifikáció

Inputgenerálás


- ▶ Véletlen bolyongás, a $[-5, 5]$ -ből egyenletesen véletlen kezdőponttal, valamint a $[0, 2]$ -ből egyenletesen véletlen lépéshosszal.
- ▶ Normális eloszlással generálódnak az idősor pontjai. A középpont a $[-5, 5]$ -ből, szórása pedig a $[0, 2]$ -ből kerül egyenletesen véletlenül kiválasztásra.
- ▶ Az előző módszerrel generálunk legalább 3, legfeljebb 10 idősort, majd ezeket konkatenáljuk.
- ▶ Több szinuszfüggvény összekeveréséből mintavételezéssel. A függvények periódusa a $[2, 10]$ -ből, amplitúdója a $[2, 10]$ -ből, átlaga pedig a $[-5, 5]$ -ből egyenletesen véletlen.




Indexméret összehasonlítása a szintetikus (felül) és valódi (alul) adathalmazokon




(a) Number of nodes




(b) Index size




(c) Average #ts per leaf




(d) # segments/node




(a) Number of nodes



(b) Index size





(c) Average #ts per leaf




(d) # segments/node




Keresés hatékonysága szintetikus (felül) és valódi (alul) adathalmazokon



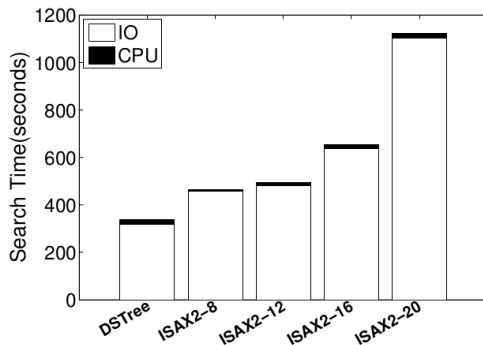
APCA (M) és EAPCA (M+SD) alsó korlát értékek összehasonlítása



Skálázhatóság összehasonlítása



Keresési idő összehasonlítása



Implementáció

DSTree implementáció

A cikk alapján megvalósítottuk az adatszerkezetet és műveleteit.

- ▶ Feltöltünk egy DSTree-t idősorokkal
- ▶ Keresünk közöttük egy új idősorhoz hasonló



Implementáció

DSTree implementáció

A cikk alapján megvalósítottuk az adatszerkezetet és műveleteit. Illusztráljuk ezt a következő példán:

- ▶ Feltöltünk egy DSTree-t idősorokkal
- ▶ Keresünk közöttük egy új idősorhoz hasonlót



Implementáció

DSTree implementáció

A cikk alapján megvalósítottuk az adatszerkezetet és műveleteit. Illusztráljuk ezt a következő példán:

- ▶ Feltöltünk egy DSTree-t idősorokkal
- ▶ Keresünk közöttük egy új idősorhoz hasonlót



Implementáció







DSTree implementáció

A cikk alapján megvalósítottuk az adatszerkezetet és műveleteit. Illusztráljuk ezt a következő példán:

- ▶ Feltöltünk egy DSTree-t idősorokkal
- ▶ Keresünk közöttük egy új idősorhoz hasonlót



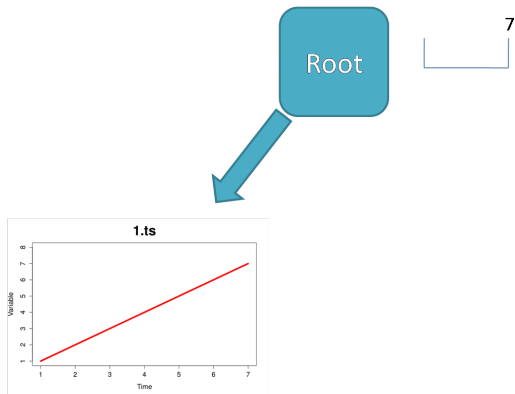
Idősorok



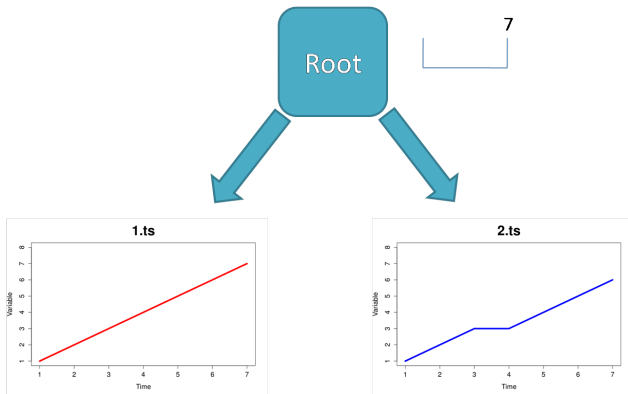
DSTree felépítése



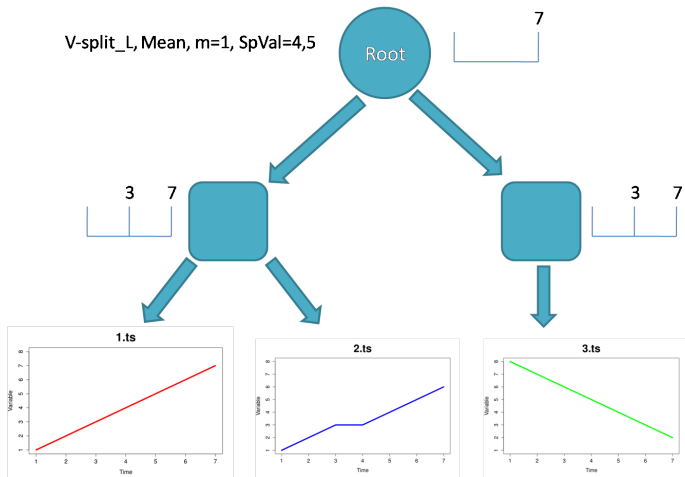
DSTree felépítése



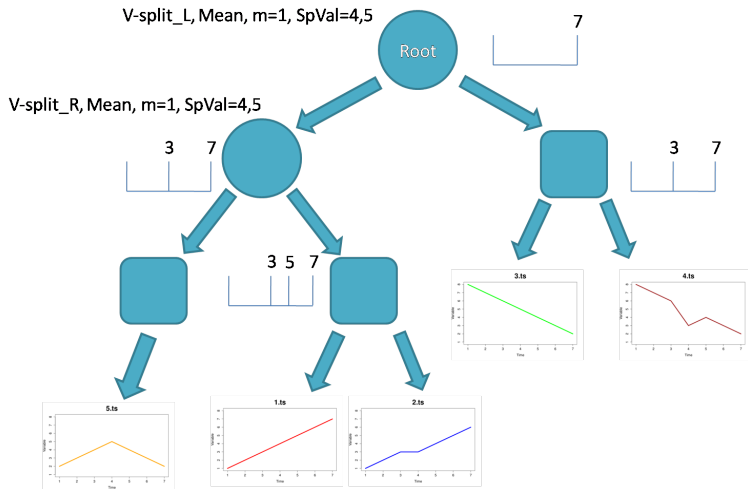
DSTree felépítése



DSTree felépítése




DSTree felépítése

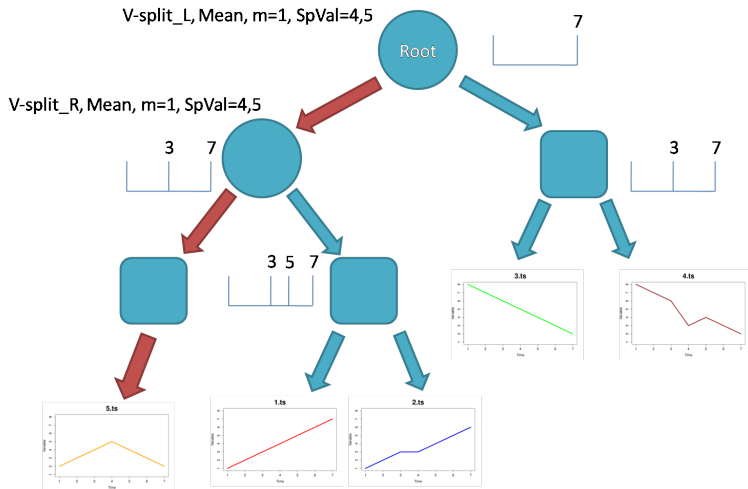


Heurisztikus keresés

6.ts



Heurisztikus keresés



Tartalom

Bevezetés

Módszerek

Eredmények

Összefoglalás



Összefoglalás

Útravaló

- ▶ Adaptív, dinamikus szegmentálással jelentősen javítani lehet a keresési időn
- ▶ Érdemes lehet áttérni EAPCA reprezentációra
- ▶ DSTree-t fontos tovább vizsgálni
- ▶ Standard tesztadatok hiánya



Összefoglalás

Útravaló

- ▶ Adaptív, dinamikus szegmentálással jelentősen javítani lehet a keresési időn
- ▶ Érdemes lehet áttérni EAPCA reprezentációra
- ▶ DSTree-t fontos tovább vizsgálni
- ▶ Standard tesztadatok hiánya



Összefoglalás

Útravaló

- ▶ Adaptív, dinamikus szegmentálással jelentősen javítani lehet a keresési időn
- ▶ Érdeemes lehet áttérni EAPCA reprezentációra
- ▶ DSTree-t fontos tovább vizsgálni
- ▶ Standard tesztadatok hiánya



Összefoglalás

Útravaló

- ▶ Adaptív, dinamikus szegmentálással jelentősen javítani lehet a keresési időn
- ▶ Érdeemes lehet áttérni EAPCA reprezentációra
- ▶ DSTree-t fontos tovább vizsgálni
- ▶ Standard tesztadatok hiánya



Köszönetnyilvánítás

Köszönjük a figyelmet!

