

Ortog. aproks. imaju tu prednost da koeficijenti za aproks. do nekeg stupnja ostaju isti i za sljedeći stupanj - pa treba računati samo jedan novi koef. - i to najniži - pri povećanju stupnja polinoma.

Ovo svojstvo važi za sve ortogonalne aproksimacije.

4.1.6. Forsythe-or algoritam

Vidjeli smo da za euklidskautnu mrežu ne treba posebno generirati ortogonalne polinome na bazi nekih rekurzivnih formula, jer postoje eksplisitne formule.

Ako mreža nije euklidska, onda treba generirati redom ortogonalne polinome. Pošto su ortogonalni polinomi zadovoljavaju tročlane homogene rekurzivne oblike

$$p_{j+1}(x) = (x - \alpha_{j+1}) p_j(x) - \beta_j p_{j-1}(x)$$

dodano je iz uvjeta ortogonalnosti na zadanoj mreži nalaziti koeficijente β_j, α_{j+1} da nastanu novi polinom.

Za to postoji vrlo elegantan algoritam koji u kombinaciji sa generaliziranom Homerovom shemom odmah daje vrlo efikasni algoritam za nalazenje polinoma po metodi najmanjih kvadrata.

- Algoritam se zove Forsythe-or po George F. Forsythe-u koji ga je pronašao 1957. €

Algoritam se sastoji iz 2 faze:

1. faza: generiranje ortogonalnih polinoma
2. faza: računanje koeficijenata aproksimacije

- Po prvi put još uočimo i općenitiji oblik metode najmanjih kvadrata u tome je srakom podatku podjeljena i određena teorija koja govori o tome koliko je prihvatljivo želimo da taj podatak ima na finalni rezultat, a uodi se iz statističkih razloga da se uključi i sigurnost odn. pouzdanost podatka u aproksimaciju, jer se u praksi podaci najčešće

dobitaju ujeravanja i statističom analizom tih ujeravanja.

Tezine će p. imati posebnu, vrlo bitnu ulogu u nepredviđenoj metodi najmanjih kvadrata, pa ih sada uvodimo zbog analogije.

- Zadan je skup podataka - točaka

$$(1) \quad (x_i, y_i), \quad i=1, \dots, n$$

s težinama $w_i, \quad i=1, \dots, n$

- Taj uz podataka želimo aproksimirati polinomom p stupnja m , kojeg želimo prikazati kao linearnu kombinaciju ortogonalnih polinoma na toj unosi $\{x_1, \dots, x_n\}$ uz zadane težine. Dakle, tražimo polinom-funkciju $p \in X$ u formi

$$(2) \quad p = \sum_{j=0}^m a_j P_j$$

gdje su P_0, \dots, P_m ortogonalni polinomi na toj unosi \mathcal{H} -vari:

$$(3) \quad \langle P_k, P_\ell \rangle = \sum_{i=1}^n w_i P_k(x_i) P_\ell(x_i) = 0$$

ako je $k \neq \ell$

(\mathcal{H} -težine, naravno, ulaze i u skal. produkt).

- Takav uz polinoma generiran je slijedećom rekurzijom:

$$(4) \quad P_k(x) = (x - \alpha_{k-1}) P_{k-1}(x) - \beta_{k-1} P_{k-2}(x)$$

za $k=1, 2, \dots, m$

uz početak $P_{-1}(x) = 0,$
 $P_0(x) = 1,$

(možemo krenuti od $P_0(x) = 1, P_1(x) = x - \alpha_0,$ ali onda treba prvo ući α_0).

- Za koeficijente $\alpha_{k-1}, \beta_{k-1}$ važe ove formule:

$$(5) \quad \alpha_{k-1} = \frac{\sum_{i=1}^n w_i x_i P_{k-1}^2(x_i)}{\sum_{i=1}^n w_i P_{k-1}^2(x_i)}, \quad k=1, \dots, m$$

ili $\alpha_{k-1} = \frac{\langle \text{id} \cdot P_{k-1}, P_{k-1} \rangle}{\langle P_{k-1}, P_{k-1} \rangle},$ gdje je id identiteta $\text{id}(x) = x$

$$(6) \quad \beta_{k-1} = \frac{\sum_{i=1}^n w_i x_i P_{k-1}(x_i) P_{k-2}(x_i)}{\sum_{i=1}^n w_i P_{k-2}^2(x_i)}, \quad k=2, \dots, m$$

$$\text{ili } \beta_{k-1} = \frac{\langle \text{id} \cdot P_{k-1}, P_{k-2} \rangle}{\langle P_{k-2}, P_{k-2} \rangle}.$$

(Relacije (5), (6) se direktno dobivaju primjenom ortogonalnosti u relaciji (4)).
 - Koeficijenti a_j u razvoju aproksimacione funkcije su dati sa:

$$(7) \quad a_j = \frac{\sum_{i=1}^n w_i y_i P_j(x_i)}{\sum_{i=1}^n w_i P_j^2(x_i)}, \quad j=0, \dots, m$$

$$\text{ili } a_j = \frac{\langle y, P_j \rangle}{\langle P_j, P_j \rangle} \quad (\text{ti kao i ranije!}).$$

- Kad smo jednom našli sve koeficijente a_0, \dots, a_m onda se računanje aproksimacije $p(x)$ u raznim točkama x provodi generaliziranim Hornerovom shemom, pa nije doručno vratiti samo a_j , već treba vratiti i koeficijente α_k, β_k iz rekurzije.

- Požarimo na primjeru kako ide primjena ovog algoritma

Primjer: (detekcija polinoma)

Uzmimo polinom $y(x) = x^2 + 4x + 7$ i tabeliramo ga u točkama $x_i = 0 + (i-1) \cdot \frac{1}{2}$, $i=1, \dots, 5$

Tablica je:

x_i	0	0.5	1	1.5	2
y_i	7	9.25	12	15.25	19

i perturbiramo malo ove podatke za 0.5 i 1.5 u

x_i	0	0.5	1	1.5	2
y_i	7	9.3	12	15.2	19

Za sve točke uzimamo 1, $w_i = 1$, jer su svi polarni podaci bili jednako povzdani.

Travimo aproksimaciję polinomima po metodi
 najmaujih kvadratų, su tim da oželujemo da
 kvadratui polinom više nema greškę \emptyset , zbog
 perturbacija.

Redom je: $P_0(x) = 1$, i definiramo $\beta_0 = 0$.

- Računamo P_1 :

$$\alpha_0 = \frac{\sum_{i=1}^5 x_i \cdot 1}{\sum 1} = \frac{1}{5} \cdot \sum x_i = \frac{5}{5} = \underline{1}$$

$$\Rightarrow \underline{P_1(x) = x - 1}$$

- Računamo P_2 :

$$\beta_1 = \frac{\sum x_i P_1(x_i) \cdot 1}{\sum 1^2} = \frac{1}{5} \sum_{i=1}^5 x_i (x_i - 1)$$

$$= \frac{1}{5} \cdot (\emptyset \cdot (-1) + \emptyset.5 \cdot (-\emptyset.5) + 1 \cdot \emptyset + 1.5 \cdot (\emptyset.5) + 2 \cdot 1)$$

$-\emptyset.25$
 $\emptyset.75$
 2

$$= \frac{2.5}{5} = \underline{\emptyset.5}$$

$$\alpha_1 = \frac{\sum_{i=1}^5 x_i P_1^2(x_i)}{\sum_{i=1}^5 P_1^2(x_i)} = \frac{\emptyset \cdot 1 + \emptyset.5 \cdot (\emptyset.25) + 1 \cdot \emptyset + 1.5 \cdot (\emptyset.25) + 2 \cdot 1}{1 + \emptyset.25 + \emptyset + \emptyset.25 + 1}$$

\emptyset
 $\emptyset.125$
 0
 $\emptyset.375$
 2

$$= \frac{2.5}{2.5} = \underline{1}$$

$$\Rightarrow P_2(x) = (x-1) \cdot \underbrace{P_1(x)}_{(x-1)} + \emptyset.5 \cdot \underbrace{P_0(x)}_1 = x^2 - 2x + 1 - \emptyset.5$$

$$\underline{P_2(x) = x^2 - 2x + \emptyset.5}$$

Pogledajmo ~~greške~~ vrijednosti ovih polinoma u
 svim točkama

x_i	$P_0(x_i)$	$P_1(x_i)$	$P_2(x_i)$
\emptyset	1	-1	$\emptyset.5$
$\emptyset.5$	1	$-\emptyset.5$	$-\emptyset.25$
1	1	\emptyset	$-\emptyset.5$
1.5	1	$\emptyset.5$	$-\emptyset.25$
2	1	1	$\emptyset.5$

pa vidimo simetričnost raspodjele, a suma
 grešaka je \emptyset .

Nadamo još koeficijente u razvoju a_0, a_1, a_2

$$a_0 = \frac{\sum y_i}{28} = \frac{1}{5} \sum y_i = \frac{62.5}{5} = \underline{12.5}$$

$$a_1 = \frac{\sum y_i \cdot P_1(x_i)}{\sum P_1^2(x_i)} = \frac{-7 - 9.3/2 + 0 + 15.2/2 + 19}{2.5 \text{ (većimali)}} = \frac{14.95}{2.5}$$

$$= \underline{5.98}$$

$$a_2 = \frac{\sum y_i P_2(x_i)}{\sum P_2^2(x_i)} = \frac{\frac{7}{2.8} - \frac{9.3}{4} - \frac{12}{2} - \frac{15.2}{4} + \frac{19}{2}}{\frac{1}{4} + \frac{1}{16} + \frac{1}{4} + \frac{1}{16} + \frac{1}{4} = \frac{7}{8}} = \frac{0.875}{1} = \underline{0.875}$$

⇒ Aproksimacija:

0. stupnja je: $p_0 = a_0 P_0 = \underline{12.5}$

1. stupnja je: $p_1 = p_0 + a_1 P_1 = 12.5 + 5.98(x-1)$
 $= \underline{5.98x + 6.52}$

2. stupnja je: $p_2 = p_1 + a_2 P_2 = 5.98x + 6.52 + 1(x^2 - 2x + 0.5)$
 $= \underline{x^2 + 3.98x + 7.02}$

pa je p_2 i po koeficijentima vrlo točno.

- Pripadnu sumu kvadrata aps. grešaka su:

$$S_0 = 91.155$$

$$S_1 = 0.879$$

$$S_2 = 0.004$$

→ odavde zaključujemo da je
 više o blago perturb.
 podacima u kvadrat pol.

a tablice funkcijehi uzajednosti:

x_i	y_i	$P_0(x_i)$	$P_1(x_i)$	$P_2(x_i)$
0	7	12.5	6.52	7.02
0.5	9.3	12.5	9.51	9.26
1	12	12.5	12.5	12.00
1.5	15.2	12.5	15.49	15.24
2	19	12.5	18.48	18.98

jer je
 S uaglo
 kao.
 Za S_3
 dolili li
~~pa~~
 još mogu
 ali ne bitno
 i koef.
 a_3 liho
 vrlo mali
 pa stajemo.

Nap. Za S-ove smo mogli konstat. i formulu
 12 Zad 5.

Ovaj algoritam je vrlo pogodan za iterativno konstante i tehnike - tj. iolemo tako daleko podizati stupanj dož nam S ne padne dovoljno nisko - i onda stajemo, a prava pogodnost je i opet to što za novi stupanj treba izračunati samo jedan koeficijent - ovaj uz najviši (tj. novi) polinom u razvoju, a svi ostali su isti.

Zadatak 6. Formuliraj algoritam i program za Forsythe-ov algoritam u varijanti sa fiksnim stupnjem, i u varijanti sa podizanjem stupnja sve dož S ne padne ispod zadane pragu (tada treba vratiti i stupanj!) (tv. detekcija polinoma). Obrati pažnju na to da treba vratiti i koef. α, β za kasnije izvedivanje. Također organiziraj efikasno konstante memorije za vrijednosti $P_k(x_i)$. Koliko polja je neophodno potrebno.

Zadatak 7. Usporedi broj operacija za MLS direktno polinomom (na pr. uz Gauss-eliminaciju sa ili bez pivota) i za MLS diskretnom ortogonalnošću. Posebno usporedi broj operacija za pravac i parabolu ($m=1, 2$).

Napomena: MLS se vrlo često koristi i za tv. izglacivanje podataka - ~~tako~~ originalni podaci se zamjenjuju izračunatima po MLS. Treba paziti na preciznost aproksimacije - da zaista izglacimo nebitne oscilacije u podacima (tj. sum), a ne i bitni dio pojave. na pr.

