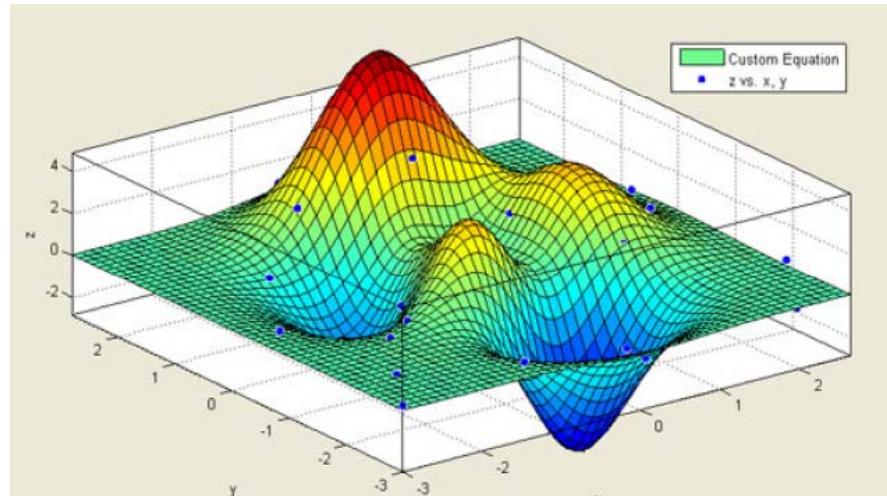


CURVE FITTING TOOLBOX



Nenad Bolf
Sveučilište u Zagrebu
Fakultet kemijskog inženjerstva i tehnologije

bolf@fkit.hr [http:// LAM.fkit.hr](http://LAM.fkit.hr)

CURVE FITTING TOOLBOX™

Podešavanje (“fitanje”) krivulja i površina shodno realnim podacima primjenom tehnika regresije (regression**), interpolacije (**interpolation**) i izglađivanja (**smoothing**).**

- Analiza podataka
- Preodbrada podataka
- Naknadna obrada podataka
- Usporedba potencijalnih modela
- Uklanjanje ekstremnih vrijednosti (**outliers**)
- Regresijska analiza s linearnim i nelinearnim modelima ili vlastitim jednadžbama
- Neparametarske tehnike modeliranja – **spline**, **interpolacija** i **izglađivanje**.

CURVE FITTING TOOLBOX

Osnovne karakteristike i funkcije

- ✓ Pregled i analiza podataka te vizualno i numeričko podešavanje
- ✓ Statistički pokazatelji za ocjenu kvalitete podešavanja
- ✓ Mogućnost ekstrapolacije, diferenciranja i integriranja
- ✓ Spremanje podataka u nekoliko formata (M-datoteke, binarno, radni prostor)

Dva načina rada

- **Grafičko korisničko sučelje (Grafical User Interface – GUI)**
- *Matlab-ov naredbeni redak (MATLAB command line)*

Za većinu zadataka preporuča se upotreba **GUI-a**.

Prije rada u *Curve Fitting Toolbox*-u varijable s podacima moraju postojati u radnom prostoru (*workspace*-u).

ŠTO JE CURVE FITTING TOOLBOX?

Pokretanje grafičkog sučelja:

Utipkati **cftool** u *Command prompt*-u

Čemu služi ovaj toolbox?

- **Predobrada** podataka
 - podjela na sekcije (**sectioning**) i izglađivanje podataka (**smoothing**)
- **Podešavanja (fitting):**
 - **parametarsko** podešavanje (polinomne, eksponencijalne i racionalne funkcije, sume Gaussovih funkcija, posebne jednadžbe itd.)
 - **neparametarsko** podešavanje
spline ili **interpolacije** – standardne linearne i nelinearne metode najmanjih kvadrata, robusni postupci podešavanja

PREDOBRADA PODATAKA – IZGLAĐIVANJE

IZGLAĐIVANJE (smoothing)

- Ako su podaci opterećeni **šumom** primjenjuje se **algoritam izglađivanja** kako bi se olakšalo parametarsko podešavanje;
- Dvije **osnovne pretpostavke** za izglađivanje su:
 - veza između **odziva** i **prediktora** (nezavisne varijable) je glatka,
 - postupak izglađivanja daje rezultate koji daju bolju procjenu originalnih vrijednosti jer je šum smanjen;
- Izglađivanje se može smatrati lokalnim podešavanjem jer se nove vrijednosti generiraju za svaku originalnu vrijednost odziva;
- Prema tome, izglađivanje je slično neparametarskom podešavanju (npr. **smoothing spline** ili **cubic interpolation**);
- Ipak, ova vrsta podešavanja razlikuje se od parametarskog čiji rezultat su **globalni parametri**.

METODE IZGLAĐIVANJA

Filtiranje (**averaging**) i lokalna regresija

- Kod svake metoda definira se određeni raspon (**span**) – područje susjednih točaka koje se uključuju u proračun nove točke;
- Ovaj raspon se pomiče duž podataka korak po korak za svaku novu vrijednost prediktora;
 - **Veliki raspon** povećava glatkoću, ali **smanjuje rezoluciju** izglađenih podataka;
 - **Mali raspon** smanjuje glatkost, ali **povećava rezoluciju** izglađenih podataka;
- Optimalni raspon ovisi o skupu podatka, metodi izglađivanja i obično zahtijeva ponešto eksperimentiranja.

METODE IZGLAĐIVANJA – Moving average filtering

Moving average filtering

- Filtar koji **propušta niske frekvencije** i uzima sredinu od susjednih podataka;
- Izglađuje podatke tako da **svaki podatak zamjenjuje sa srednjom vrijednosti susjednih točaka definiranih rasponom**;
- Rezultat je dan s jednadžbom razlika:

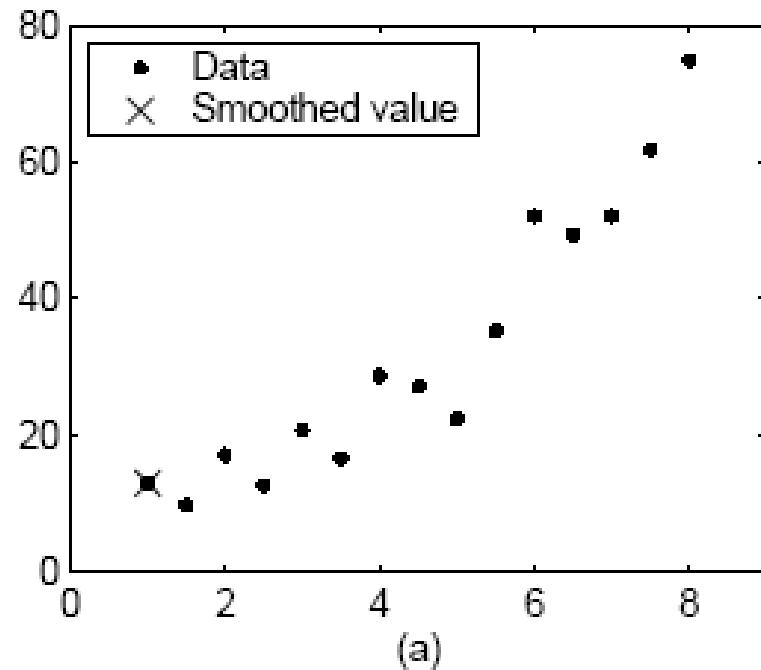
$$y_s(i) = \frac{1}{2N+1}(y(i+N) + y(i+N-1) + \dots + y(i-N))$$

$y_s(i)$ izglađena vrijednost i -tog podatka

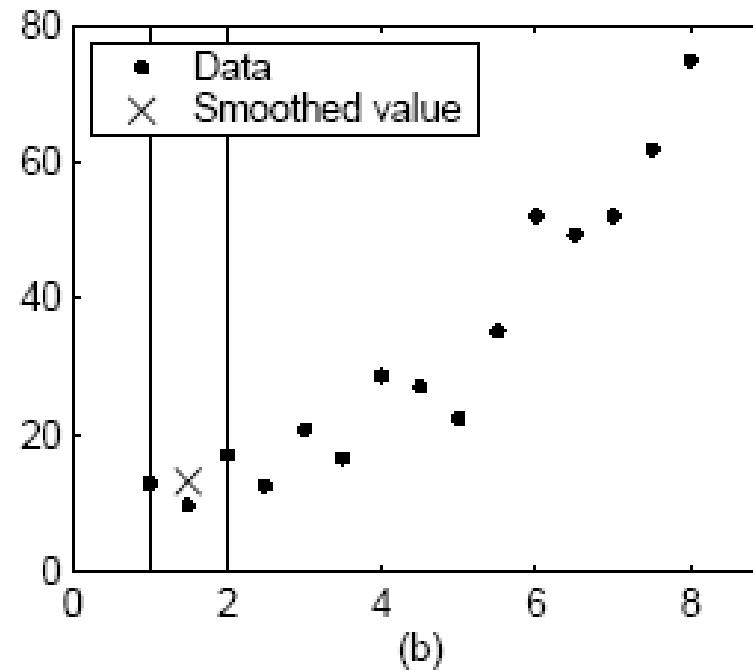
N broj susjednih podataka s obje strane $y_s(i)$

$2N+1$ raspon

MOVING AVERAGE FILTRIRANJE



(a)



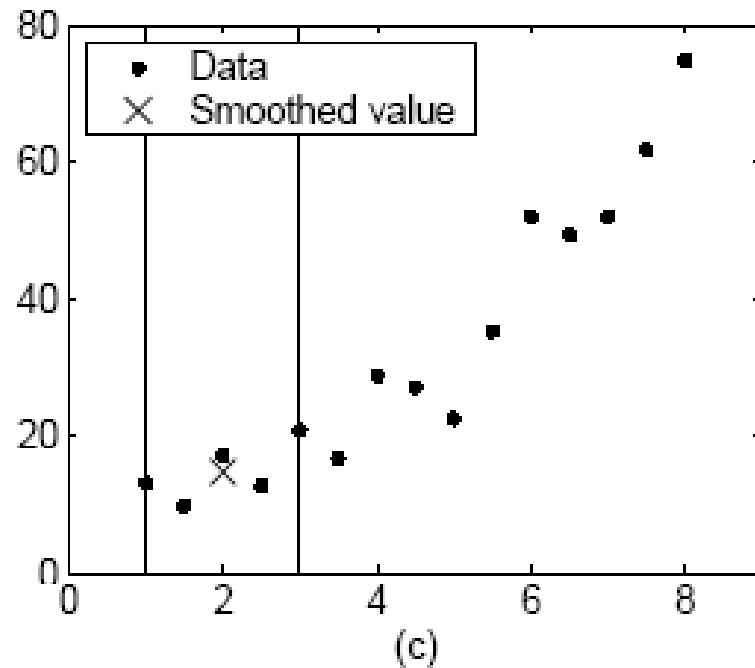
(b)

- (a) Prva točka nije izglađena jer ne postoji raspon
- (b) Druga točka je izglađena primjenom raspona od tri podataka

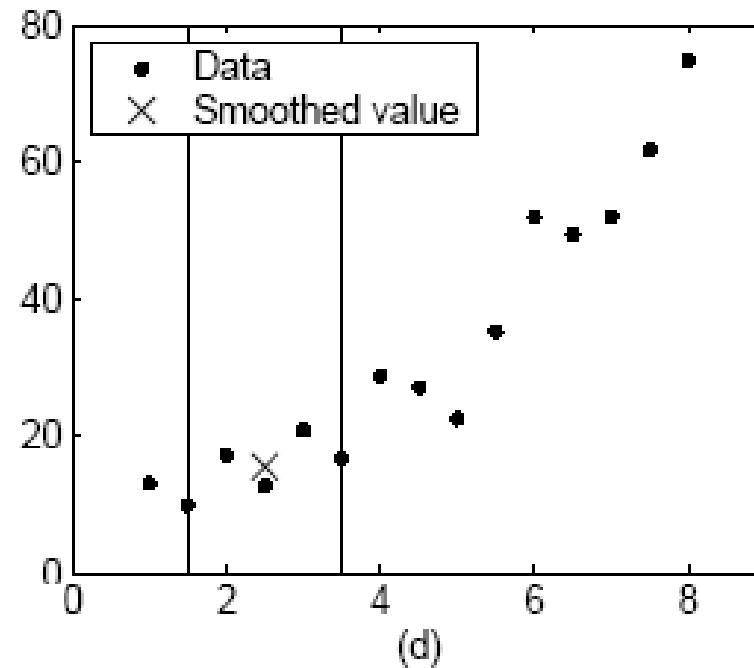
$$y_s(1) = y(1)$$

$$y_s(2) = (y(1)+y(2)+y(3))/3$$

MOVING AVERAGE FILTRIRANJE



(c)



(d)

(c) i (d) za proračun izglađene vrijednosti primjenjuje se raspon od 5 točaka

$$y_s(3) = (y(1)+y(2)+y(3)+y(4)+y(5))/5$$

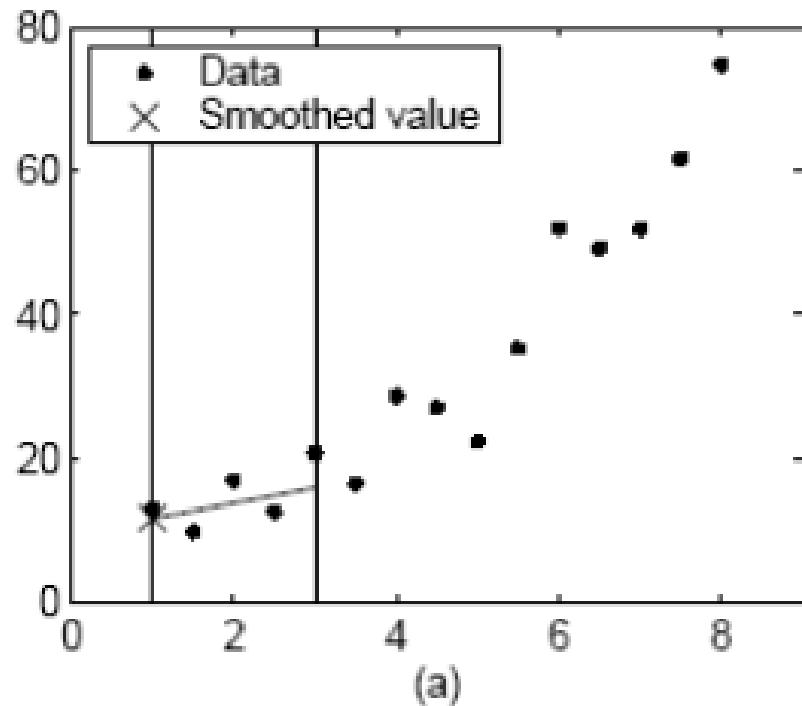
$$y_s(4) = (y(2)+y(3)+y(4)+y(5)+y(6))/5$$

LOWESS i LOES – izglađivanje primjenom lokalne regresije

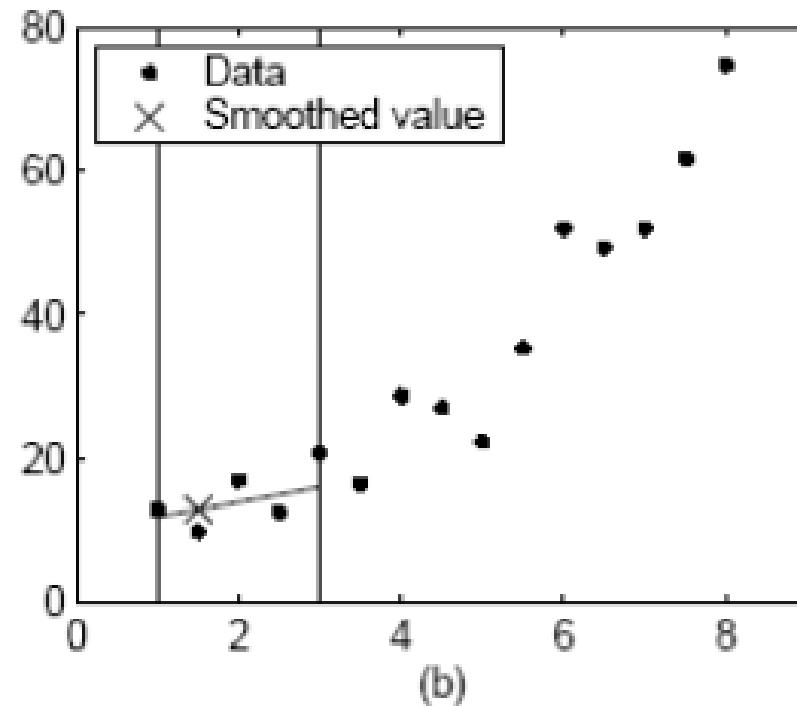
Lowess, loess – “*locally weighted scatter plot smooth*”

- Obje metode primjenjuju **lokalnu težinsku** linearu regresiju;
- Smatra se “**lokalnom**” jer se vrijednost određuje na temelju **susjednih točaka** definiranih rasponom;
- Podaci imaju svoje težinske vrijednosti, a primjenjuje se i robusna težinska funkcija kako bi isključile ekstremne vrijednosti (**outlier**-i)
- **Lowess** – primjena linearnog polinoma 1. reda
Loess – primjena kvadratnog polinoma 2. reda
- U CFT-u vrijede slijedeća pravila:
 - raspon može obuhvatiti neparan ili paran broj podataka
 - raspon se specificira kao postotak ukupnog broja podatka
(npr. 0,1 znači 10% podataka)

LOWESS i LOES – izglađivanje lokalnom regresijom



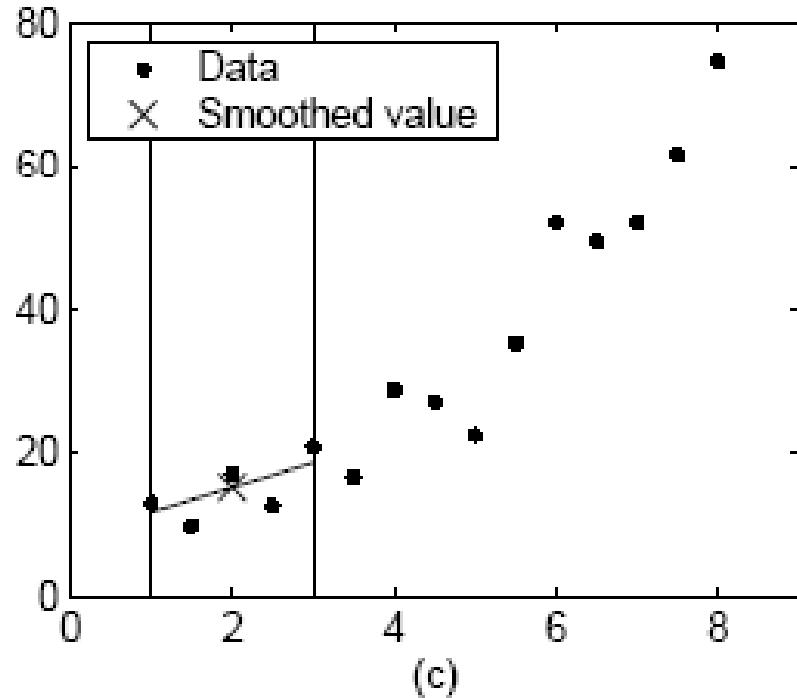
(a)



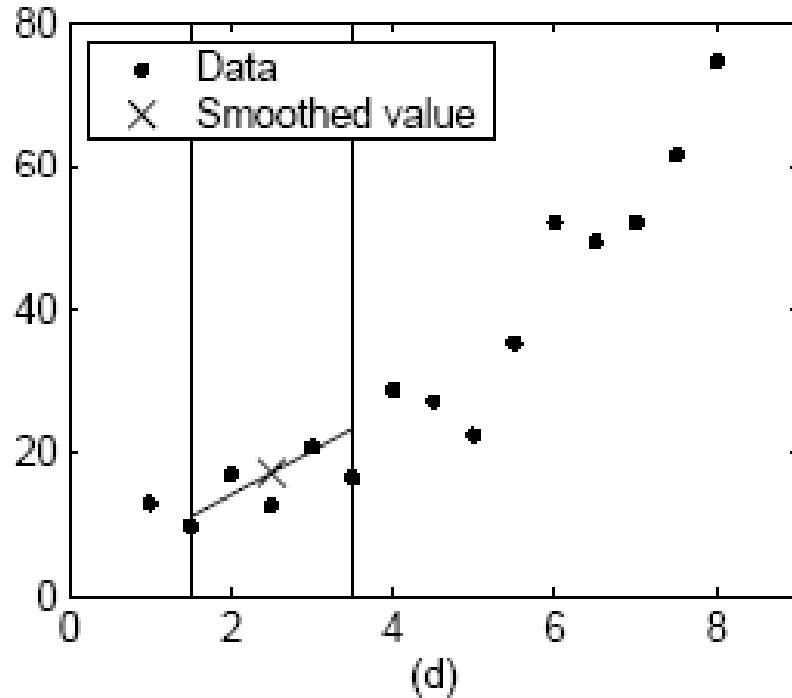
(b)

Raspon je stalan, a postupak izglađivanja provodi se od točke do točke. Kod (a) i (b) upotrebljava se asimetrična težinska funkcija

LOWESS i LOES – izglađivanje lokalnom regresijom



(c)

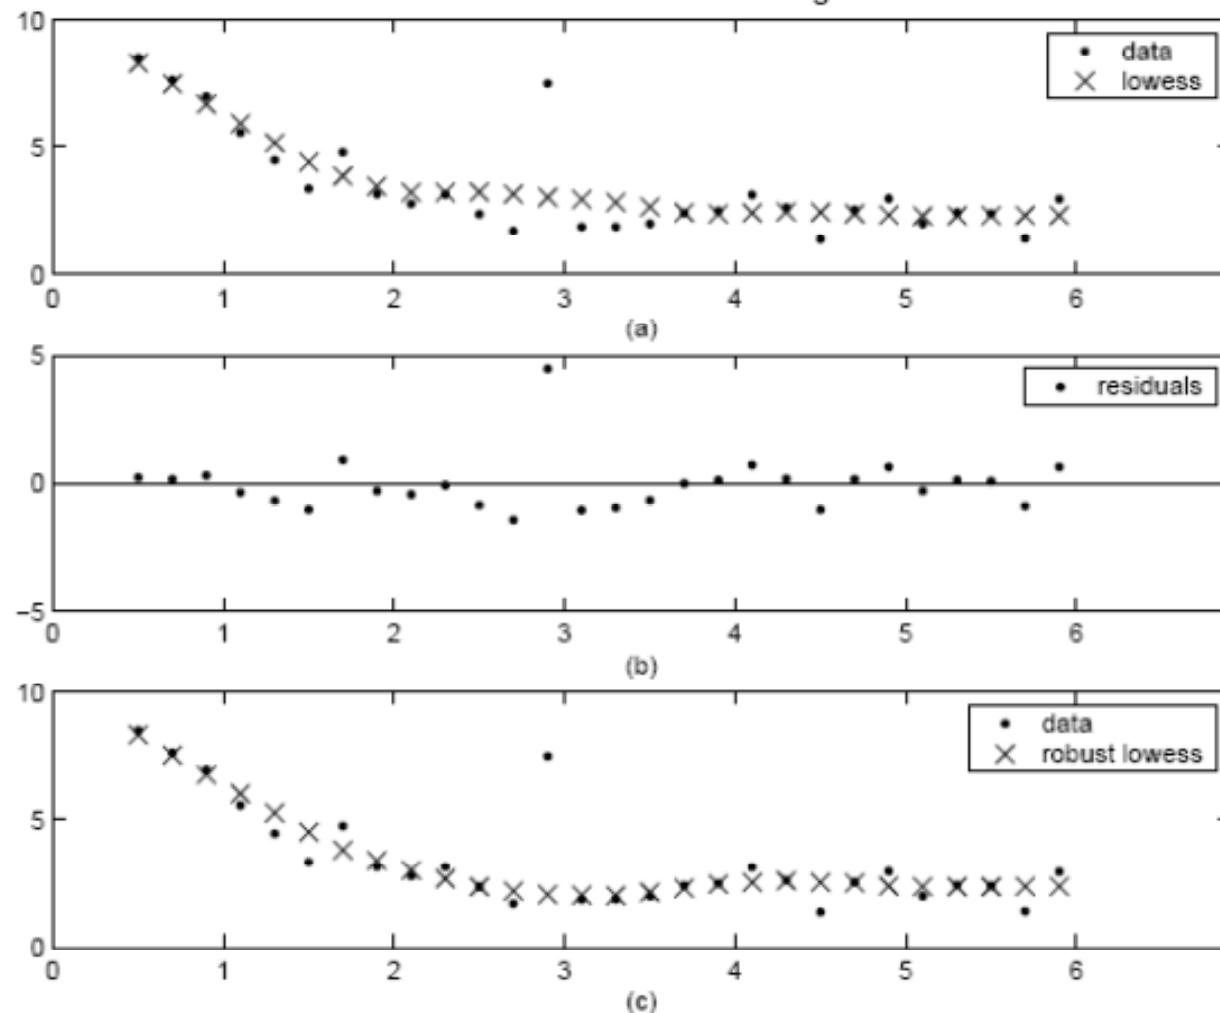


(d)

Ovisno o broju najbližih susjeda, težinske funkcije ne moraju biti simetrične oko točke oko koje se izglađuje.

Kod (c) i (d) upotrebljava se simetrična težinska funkcija.

LOWESS i LOES – Robusno izglađivanje

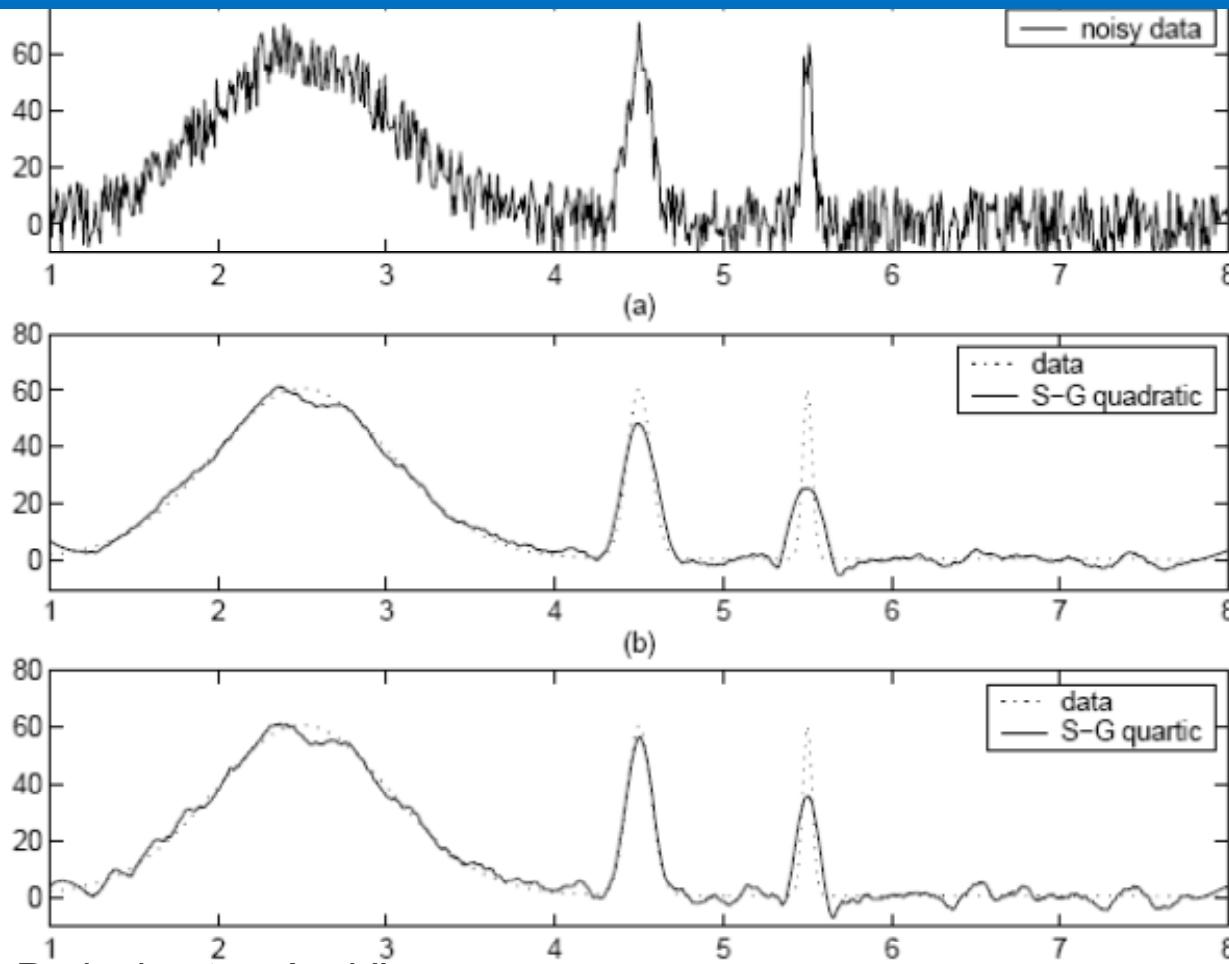


- (a) *Outlier utječe na izglađenu vrijednost za nekoliko susjednih točaka*
- (b) *Prikaz ostataka – veći su od 6 medijana apsolutnih odstupanja*
- (c) *Izglađene vrijednosti oko outlier-a odražavaju većinu podataka*

SAVITZKY-GOLAY FILTAR

- Poopćeni “*moving average*” postupak pri čemu se određuje koeficijent filtra provedbom netežinskog podešavanja linearnom metodom najmanjeg kvadrata primjenom polinoma određenog stupnja (naziva se još i digitalni polinomski filter za izglađivanje – **digital smoothing polynomial filter** ili **least squares smoothing filter**)
- Višim redom polinoma može se postignuti visoka razina izglađivanje bez prigušenja podataka
- Često se koristi pri obradi frekvencijskih ili spektroskopskih podataka (s pikovima)
- Kod frekvencijske analize djelotvoran je za očuvanje visokofrekventnih komponentnih signala
- Kod spektroskopske analize dobar je za očuvanje vrhova pikova
- Za usporedbu, MA filtrira veliki dio visokofrekventnog sadržaja, a SG je manje uspješan od MA kod skidanja šuma

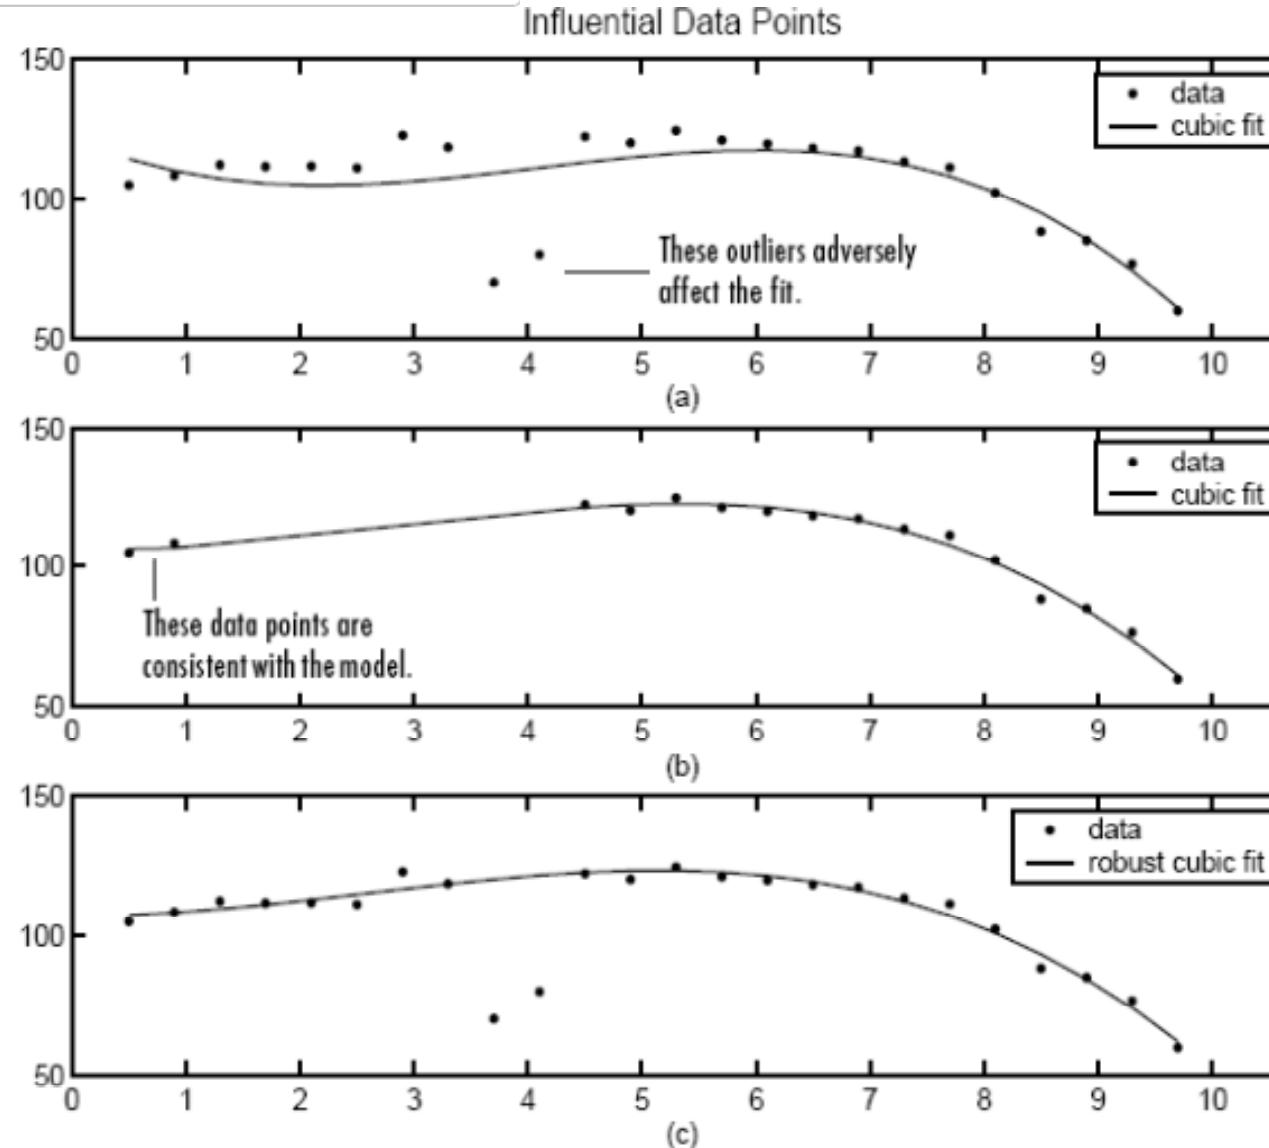
SAVITZKY-GOLAY FILTAR



- (a) Podaci opterećeni šumom
- (b) Podaci bez šuma – izglađivanje kvadratnim polinom, ima problema s uskim pikovima
- (c) Podaci bez šuma – izglađivanje kvartnim polinomom; općenito, što je veći red bolje se “hvataju” uski pikovi, ali slabije širi

ISKLJUČIVANJE I PODJELA PODATAKA

- Ako postoji potreba, dio podataka može se **isključiti** iz skupa za podešavanje;
- Obično se isključuju podaci koji bi mogli **poremetiti** slijedeća podešavanja u nizu;
(npr. podešavanje parametarskog modela s mjernim podacima kod kojih postoji **prekid zbog kvara senzora**)
- Unutar CFT podaci se isključuju na dva načina:
 - **Obilježavanje outlier-a (marking outliers)**
Outlieri su **pojedine točke** koje su **nekonzistentne** sa statističkim karakteristikama ostalih podataka
(npr. gruba mjerne pogreška, podatak koji znatno odstupa)
 - **Podjela na sekcije (sectioning)**
Isključuje dio podataka
(npr. odvajanje većeg dijela podataka zbog sustavne pogreške)



- (a) dva *outlier-a* bitno utječu na podešavanje
- (b) dva podatka koja su konzistentna s modelom
- (c) robusni postupak prihvatljiva je alternativa za obilježavanje *outlier-a*

DODATNI KORACI PRI PREDOBRADI

- Dodatni koraci pri predobradi koji nisu dostupni u CFT su:
 - **transformiranje podataka**
 - **uklanjanje *INFs*, *NANs* i *outlier-a***
- U nekim slučajevima potrebno je podatke **transformirati**;
- Obično se primjenjuje **logaritmska $\ln(y)$** i **eksponencijalna funkcija** kao što su $y^{1/2}$, y^1 ;
- Na taj način mogu se **linearizirati** modeli, **pojednostaviti** modeli koji obuhvaćaju velike raspone (npr. pH umjesto $c(H^+)$) ili se **reducira broj koeficijenata** modela;
- Iako **CFT** ignorira ***Inf*s** i ***NANs*** ponekad ih je potrebno prethodno ukloniti iz skupa podataka za što postoje odgovarajuće funkcije u MATLAB-u (***isinf***, ***isnan***).

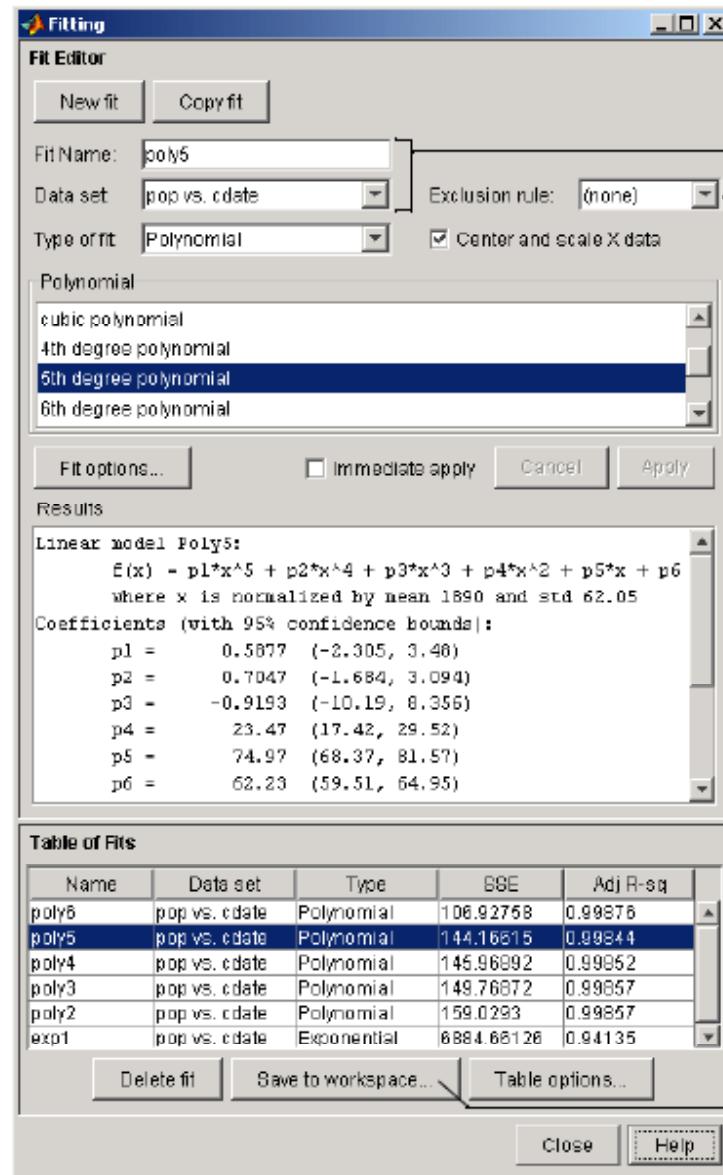
PODEŠAVANJE PODATAKA

FITTING

- Postupkom podešavanja krivulja se uskladjuje tako da slijedi postojeće eksperimentalne podatke;
- Krivulje se dobivaju tehnikama **regresije**, **spline**-om ili **interpolacijom**;
- Podaci koji se obrađuju obično su izmjereni senzorima, dobiveni simulacijom, preuzeti iz baza podataka itd.;
- Cilj podešavanja je:
 - **Dobiti uvid u podatke** koje će omogućiti da se poboljša tehnika prikupljana podataka u budućim eksperimentima,
 - **prihvati ili odbiti teorijski model**,
 - iznaći **fizikalno značenje** za koeficijente i
 - izvući **zaključak o izvornoj populaciji**.

KORACI PRI PODEŠAVANJU

- Provodi se u grafičkom korisničkom okruženju
- **Koraci:**
 1. Odabir podataka i imena
 2. Odabir pravila isključivanja
 3. Izbor metode podešavanja i validacije
 4. Usporedba rezultata podešavanja
 5. Spremanje rezultata



1. Select a data set and specify a fit name.

2. Select an exclusion rule.

3. Select a fit type, select fit options, fit the data, and evaluate the goodness of fit.

4. Compare the current fit and data set to other fits and data sets.

5. Save the selected fit results to the workspace.

PARAMETARSKO PODEŠAVANJE

- Procjena vrijednosti koeficijenata (parametara) modela;
- Pretpostavlja se da su podaci uzeti statistički i da sadrže dvije komponente:

podatak = deterministička komponenta + slučajna komponenta

podatak = fit + pogreška (slučajna)

- **fit** predstavlja model koji je funkcija nezavisne varijable (prediktora);
- **Pogreška je slučajna varijacija** koja slijedi raspodjelu vjerojatnosti (obično Gaussov);
- Podaci mogu sadržavati i sustavno odstupanje, ali se ono teško kvantificira;
- Podešeni koeficijenti mogu imati fizikalno značenje (npr. kod radioaktivnog raspada $T_{1/2}$ (vrijeme poluraspada), obično eksponencijalni odziv s obzirom na vrijeme:

$$y = y_0 e^{-\lambda r}$$

$$\text{podatak} = y_0 e^{-\lambda t} + \text{pogreška}$$

PROVJERA VALJANOSTI (VALIDIRANJE)

VALIDATION

- Određivanje najboljeg od svih primjenjenih podešavanja;
- Da bi odredili najbolje podešavanje, potrebno je pregledati rezultate podešavanja **grafički** i **numerički**
- Početno se obično pregledavaju grafički prikaz rezultata i ostatka (**residual**);
- Numerička provjera na dva načina:
 - **Goodnes of fit statistics**
(kako dobro krivulja slijedi podatke)
 - **Coefficient confidence intervals**
(interval pouzdanosti pri određivanju koeficijenta)

PROVJERA VALJANOSTI (VALIDIRANJE)

Residual

- Razlika između odziva y i modelom predviđenog odziva

$$r = y - \hat{y}$$

- Rezidui aproksimiraju slučajne pogreške;
- Ako se rezidui na grafičkom prikazu vladaju slučajno to govori da model dobro opisuje podatke;
- Ako se javlja sustavno odstupanje model nije dobar.

Goodness of fit statistics obuhvaća:

Suma kvadrata pogreške

(**SSE – the sum of squares due to error**)

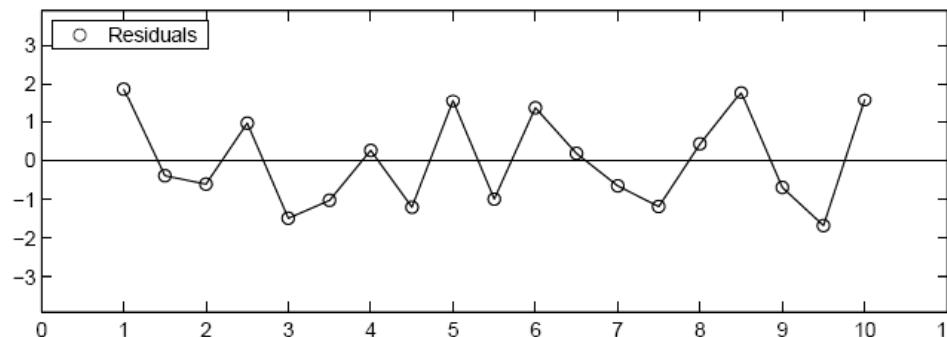
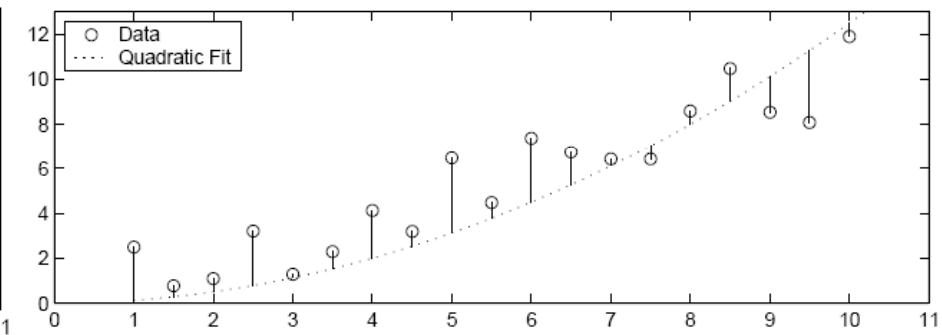
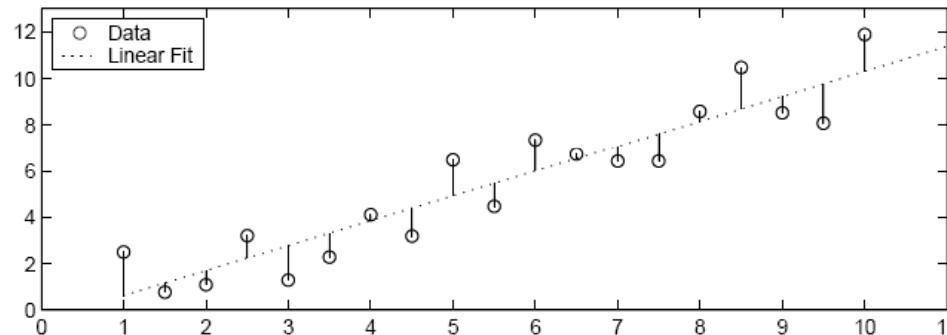
R-kvadrat (R-square)

Podešeni R-kvadrat (adjusted R-square)

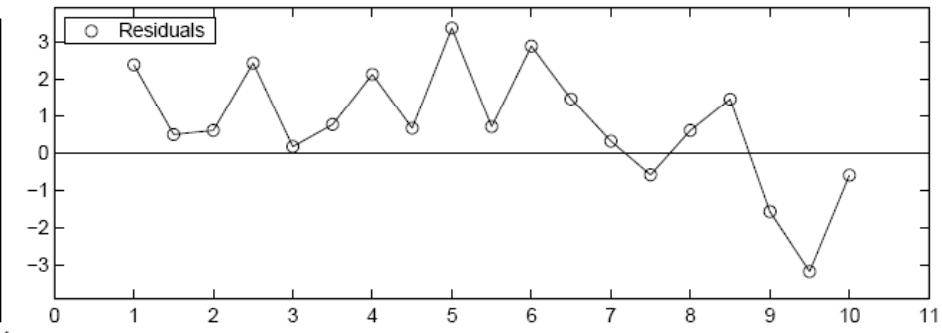
Korijen kvadrata srednje vrijednosti

(**RMSE – root mean squared error**)

PROVJERA VALJANOSTI (VALIDIRANJE)



Rezidui su slučajno raspodijeljeni oko nule što znači da model dobro opisuje podatke



Rezidui su pozitivni za većinu podataka što znači da model ne opisuje dobro podatke

NEPARAMETRSKO PODEŠAVANJE

- Primjenjuje se kada nije potrebno određivati parametre ili ih nije potrebno interpretirati;
- Kroz podatke se provlači glatka krivulja;
- U **CFT**-u postoje dvije metode:
 - **Interpolants**
procjenjuje vrijednosti koje leže između podataka
 - **Smoothing spline**
provlači glatku krivulju koja prolazi kroz podatke
- Razina “izglađivanja” može se podesiti **promjenom parametara** koji korigiraju krivulju od ravne linije (aproksimacija metodom najmanjih kvadrata) do cubic *spline* interpolanta.

IZGLAĐUJUĆI SPLINE (SMOOTHING SPLINE)

- Ako su podaci **opterećeni šumom** dobro je primijeniti **izglađujući spline**;
- Karakteriziraju ga parametar p i težine w_i
- Minimizira se:

$$p \sum w_i (y_i - s(x_i))^2 + (1-p) \int \left(\frac{d^2 s}{dx^2} \right)^2 dx$$

$0 < p < 1$
 $p = 0 \rightarrow \text{least square straight line fit}$
 $p = 1 \rightarrow \text{cubic spline interpolant}$

- Ako težine nisu definirane pretpostavlja se da su jednake 1;
- Ako se ne definira *smoothing* parametar, automatski se odabire u “*interesting range*”-u $1/(1+h^3/6)$ pri čemu je h razmak između točaka
- Pošto *smoothing spline* ima parametar može ga se smatrati i parametarskim, no on je i *piecewise* polinomski kao npr. *cubic spline* ili *shape-preserving interpolants*, no u **CFT**-u se smatra neparametarskim.