



# The Sparse Kernel Machine Model for Time Series Prediction

Laurentiu Bucur

Coordonator: Prof. Dr. Ing. Adina Magda Florea



# Sparse Kernel Machines and High Performance Computing

Laurentiu Bucur

Coordonator: Prof. Dr. Ing. Adina Magda Florea

- Contributii la modelul de Masina Kernel Rara
  - Aplicatii in finante si trafic

# Cuprins

- Preliminarii: Predictie, Spatii Hilbert RKHS
- Kernel Ridge Regression
- Modele de Masini Kernel Rare (SKM):
  - SKM utilizand atractori
  - Masini suport vectoriale pentru regresie
- Contributie: Tehnici de predictie in haos. Studiu comparativ pentru serii de timp financiare.
  - Accent pe Masinile Kernel Rare
- Concluzii

# Preliminarii

- Predictia seriilor de timp

Fie  $\{y_n\}_{n \in Z}$  o serie de timp generata de:

$$y_n = f(x_1, x_2, \dots, x_N)_n + \varepsilon_n$$

- $f$  = componenta determinista necunoscuta
- $\{\varepsilon_n\}_{n \in Z}$  componenta stohastica : zgomot cu medie 0 si distributie de probabilitate  $P_\varepsilon(\varepsilon)$ . De obicei  $P_\varepsilon(\varepsilon)$  : distributia Gaussiana  $G(0, \sigma^2)$  cu medie 0 si varianta  $\sigma^2$ .

# Preliminarii

$f$  se aproximeaza prin invatare cu  $\hat{f}: \mathbb{R}^K \rightarrow \mathbb{R}$

aleasa dintr-o familie  $\mathbf{F}$  de functii:

$$\hat{f} = \operatorname{argmin}_{g \in \mathbf{F}} \sum_{i=1}^n L(g(X_i), y_i)$$

- Doar  $K$  din  $N$  variabile ale modelului lui  $f$  pot fi **observabile**

# Preliminarii

$L(x,y)$  este o functie eroare:

- $L(x,y) = (x-y)^2$  eroarea patratica,

$$RSS = \sum_{i=1}^m (\hat{f}(X_i) - y_i)^2$$

*sau*

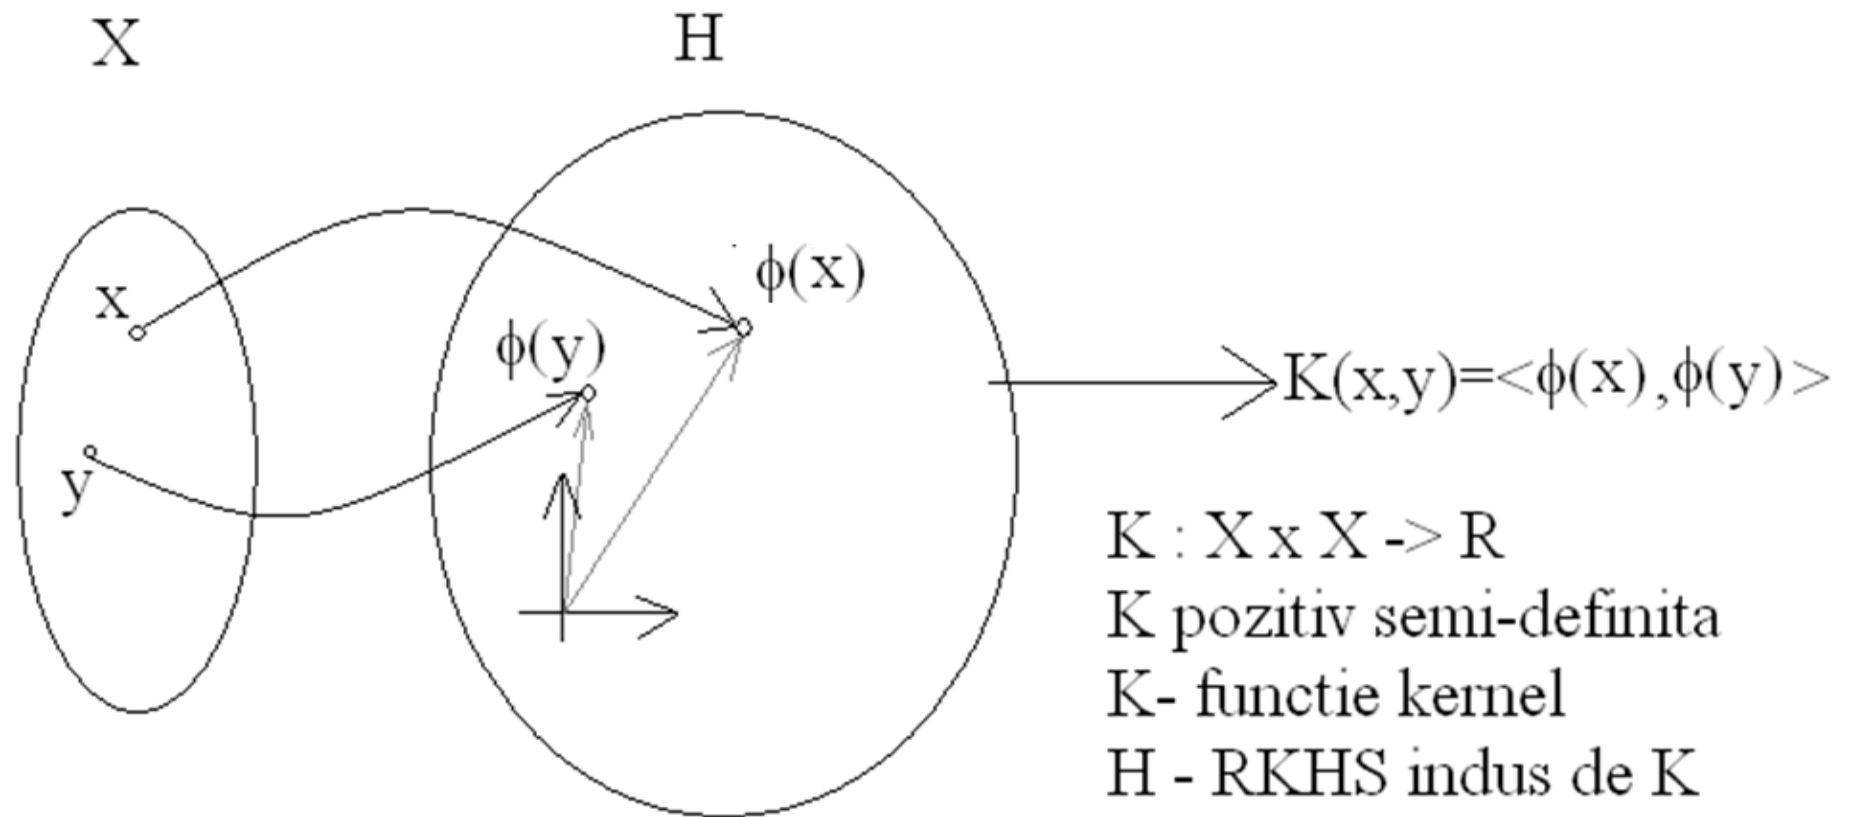
- $L(x, y) = \begin{cases} |x - y| - \varepsilon, & \text{if } |x - y| \geq \varepsilon \\ 0, & \text{altfel} \end{cases}$

$\varepsilon$ -insensitive loss

# Spatii Hilbert RKHS

- $f$  se poate aproxima direct in spatiul observabil (de exemplu cu retele neuronale) sau in imaginea acestuia intr-un spatiu Hilbert de tip RKHS (cu masini kernel).
- Metode kernel: metode de ultima generatie, ulterioare anului 2000.
- Depasesc in general ca viteza si performanta alte modele de invatare statistica

# Functii Kernel






# Spatii Hilbert RKHS

- ‘Kernel trick’: nu trebuie evaluat produsul scalar in RKHS, ci evaluata doar functia kernel.
- Functiile kernel: utile in clasificare si predictie:
  - Clase neseparabile in spatiul initial  $X$  sunt separabile in RKHS
  - O suprafata  $g(x,y,z\dots) = 0$  in  $X$  se mapeaza intr-un hiperplan  $h(\phi(x), \phi(y), \dots) = 0$  in RKHS, deoarece spatiile Hilbert sunt infinit dimensionale

Classes  $X$  and  $O$  - nonlinear separable

Linear separable in a higher dimensional Hilbert Space



Initial problem space

Rich feature space : Reproducing Kernel Hilbert Space  
(RKHS)

# RKHS al unei functii kernel

- Fie  $X$  o multime (posibil) infinit numarabila
- $K : X \times X \rightarrow \mathbf{R}$ , functie simetrica pozitiv semi-definita
- Teorema **Moore-Aronsajn** : Pentru  $K$  exista un RKHS pentru care  $K$  este Reproducing Kernel
- RKHS indus de  $K$  peste  $X$  este:

$$\mathcal{H} = \left\{ \sum_{i=1}^l \alpha_i K(x_i, \cdot) : l \in \mathbf{N}, x_i \in X, \alpha_i \in \mathbf{R}, i = 1 \dots l \right\}$$

cu produsul scalar

$$\langle f, g \rangle = \sum_{i=1}^l \sum_{j=1}^n \alpha_i \beta_j K(x_i, z_j)$$

# Kernel Ridge Regression

- Cel mai simplu model din familia de metode kernel pentru predictie
- Se folosesc toate perechile etichetate  $(x,y)$  dintr-o multime finita si numarabila  $X \times \mathbf{R}$ ,  $\text{Card}(X)=N$ , pentru invatare supervizata
- Din familia de functii:

$$\mathcal{H}_N = \left\{ \sum_{i=1}^N \alpha_i K(x_i, \cdot) \mid x_i \in X, \alpha_i \in \mathbf{R}, i = 1 \dots N \right\}$$

se calculeaza vectorul  $f$  dat de  $\alpha = \{\alpha_i\}_{i=1..N}$

# Kernel Ridge Regression

$$\alpha = (G + \lambda I_N)^{-1} y$$

G este matricea Gram (Kernel)  $N \times N$ ;

$$G_{ij} = \langle \Phi(x_i), \Phi(x_j) \rangle = K(x_i, x_j) \quad i, j = 1..N$$

$\lambda > 0$  – constanta de regularizare, aleasa apriori

Pentru calculul vectorului  $\alpha$  matricea se inverseaza utilizand metoda Conjugate Gradient, deoarece matricea este pozitiv definita si inversabila.

# Ridge Regression : Probleme

- Timpul de antrenare este  $O(N^3)$
- Pentru  $N$  suficient de mare, evaluarea masinii kernel in timp real este prohibitiva
- Kernel Ridge Regression – model generativ: se folosesc toate datele disponibile pentru a modela o distributie de probabilitate
- Clasa de metode: Kernel Density Estimation

# Masini Kernel Rare

- Este nevoie de masini kernel cu mai putini vectori baza decat modelele generative.
- Masini Kernel Rare (Sparse Kernel Machines):

$$g(\mathbf{x}) = \sum_{i=1}^m \beta_i K(z_i, \mathbf{x}) + c$$

- Exista in subspatii  $m$  - dimensionale ale spatiului Hilbert  $\mathcal{H}$  indus de  $K$
- $m \ll N$  – eficienta in stocare si executie
- Complexitate Rademacher (capacitate) redusa

# Masini Kernel Rare

$$g(x) = \sum_{i=1}^m \beta_i K(z_i, x) + c$$

-  $c, \beta_i \in \mathbb{R}, i=1..m$  – ponderi

-  $\{z_i\}_{i=1,m}$  - Setul Redus (Reduced Set - RS) al lui  $g$

$z_i \in X, i=1..m$



# Masini Kernel Rare

- 1) Se calculeaza modelul generativ  $f$  utilizand Kernel Ridge Regression
- 2) Se determina  $g$  (RS si ponderile) astfel incat sa se minimizeze distanta:

$$\|f-g\|^2 = \sum_{i,j=1}^N \alpha_i \alpha_j K(x_i, x_j) + \sum_{i,j=1}^m \beta_i \beta_j K(z_i, z_j) - 2 \sum_{i=1}^N \sum_{j=1}^m \alpha_i \beta_j K(x_i, z_j)$$

- Masina Kernel Rara – proiectia masinii kernel  $f$  pe subspatiul  $Span(RS)$

# Calculul Masinilor Kernel Rare

- Calculul RS utilizand atractori in RKHS (Lee, Jung, Lee, 2009)
- Masini Suport Vectoriale pentru Regresie (Bishop, 2006)
- Metode noi pentru calculul RS, **principalele contributii ale tezei**

# Calculul RS utilizand atractori


- Se calculeaza  $f$  utilizand Kernel Ridge Regression
- Pentru fiecare kernel  $K(x, \cdot)$  din expresia lui  $f$ :  
Se calculeaza prin integrare numerica punctul stationar  $z(x)$  al ecuatiei diferentiale:

$$\frac{dx}{dt} = -\nabla \rho(x)$$

unde:

$$\rho(x) = \|f - \Phi(x)\|^2 = \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i, x_j) + K(x, x) - 2 \sum_{j=1}^N \alpha_j K(x_j, x)$$

Attractors on class 1 data and its basin boundary



# SKM utilizand atractori

- Fiecare punct din  $X$  apartine unui singur bazin de atractie
- Centrii distincti ai bazinelor de atractie obtinuti prin integrare numerica corespund elementelor  $z_i, i=1..m$  si alcatuiesc Setul Redus (RS) al masinii kernel rare.
- Lee, Jung, Lee nu ofera o metoda obiectiva de identificare a centrilor bazinelor de atractie
- Am ales un subset ortogonal din multimea  $\{z(x_i)\}_{i=1..N}$  obtinuta prin integrare numerica:

- $K(z_i, z_j) = 0, i, j = 1..m$
- numarul  $m$  de centri din RS depinde de:
  - Functia kernel  $K$
  - Numarul si pozitia punctelor  $\{x_i\}_{i=1..N}$  din masina kernel  $f$

**Problema:** Nr. de pasi din integrarea numerica este necunoscut

- De obicei  $K$  este functia Kernel Gaussian

# Calculul ponderilor SKM

$$\beta = (K^{zz})^{-1} K^{zx} \alpha$$

unde:

- $\alpha = (\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_N)^T$  – vectorul pondere al masinii  $f$
- $K^{zz}$  - matrice kernel  $M \times M$  ,  $(K^{zz})_{ij} = K(z_i, z_j)$
- $K^{zx}$  - matrice kernel  $M \times N$  ,  $(K^{zx})_{ij} = K(z_i, x_j)$
- $\{x_i\}_{i=1..N} \subseteq X$  punctele din multimea de antrenament utilizate in expresia lui  $f$

# Masini Suport Vectoriale pentru Regresie

- **Reduced Set:** multimea punctelor  $\{x_i\}$  din setul de antrenament pentru care  $|f(x_i) - y_i| \geq \varepsilon$  sunt vectori suport pentru regresie.  $\varepsilon$  ales apriori
- Cu cat  $\varepsilon$  este mai mare cu atat nr. vectori suport este mai mic
- **Ponderile** se calculeaza utilizand optimizare convexa cu constrangeri (conditiile Karush-Kuhn-Tucker)
- Forma duala a ponderilor
- Implementare in pachetul LIBSVM



# Contributia #1 (UPB Sci. Bulletin, 2011)

- **Studiu comparativ** asupra performantei de predictie a metodelor neliniare existente, inclusiv masinile kernel rare, pe serii de timp financiare
- **Notorii pentru dificultate** : haos determinist + zgomot
- **8 perechi valutare**
- **2 indicatori ai volatilitatii** din Chicago Board of Options Exchange (CBOE): Volatility Index (**fear gauge**) si **Put-to-call Ratio**  
≈ 81000 inregistrari

# Metode analizate

- Nearest Neighbours (Hannias, Karras, 2007)
- Nearest Trajectory (McNames, 1998, 2002)
- Multiple Backprop Multi-Layer Perceptron
  - Spatiul fazelor brut
  - Spatiul fazelor seriei de timp diferenta
- Kernel Ridge Regression
- Masini Suport Vectoriale pentru regresie (SKM)
- Masini Kernel Rare utilizand atractori (Lee, Jung, Lee, 2009)

Data set no.	Original series (symbol and time frame)	Best RMSE algorithm	Best RMSE	Best directional predictor	Best directional accuracy (%)
1	VIX Daily	Kernel-Ridge	<b>1.247</b>	MBP-Global	<u><b>56.12*</b></u>
2		Kernel-Ridge, <b>SKM-Attractors</b>	<b>1.625</b>	$\epsilon$ -SVR	<u><b>55.04*</b></u>
3	Put-To-Call ratio Daily	<b><math>\epsilon</math>-SVR</b>	<b>0.273</b>	$\epsilon$ -SVR	<u><b>67.26*</b></u>
4		<b><math>\epsilon</math>-SVR</b>	<b>0.268</b>	MBP-Global	<u><b>68.81*</b></u>
5	EUR/USD 4h	Kernel-Ridge	<b>0.003</b>	MBP-Local	50.94
6		Kernel-Ridge	<b>0.003</b>	Kernel-Ridge	50.56
7	GBP/USD Daily	<b>SKM-Attractors</b>	<b>0.0097</b>	SKM-Attractors	50.86
8		Kernel-Ridge	<b>0.009</b>	MBP-Global	<b>51.51**</b>
9	GBP/USD 4h	MBP-Global	<b>0.0049</b>	MBP-Global	50.78
10		MBP-Global	<b>0.0049</b>	SKM-Attractors	<b>51.09**</b>
11	USD/CAD Daily	Nearest-Neighbours	<b>0.0062</b>	Nearest-Neighbours	<b>51.548**</b>
12		<b>SKM-Attractors</b> , MBP-Global	<b>0.0073</b>	MBP-Global	<b>52.75**</b>

# Concluzii

- **Masinile Kernel Rare:**

- Metode parametrice de predictie
- Viteza sporita de executie
- Comparabile ca performanta cu metode existente (retele neuronale, metode kernel dedicate problemei predictiei)

**Contributie:** Studiu exhaustiv al unora dintre cei mai buni algoritmi de predictie neliniara, in paralel cu modelele recent introduse (2006-2009)

# Concluzii

- Grad inalt de predictibilitate a seriilor de timp  
Volatility Index (Fear gauge) si Put-to-call ratio
- Grad scazut de predictibilitate a seriilor valutare  
– pretul de inchidere la 4 ore si zilnic
- Rezultatele analizei state of the art (metode kernel, retele neuronale): performanta **nesatisfacatoare** pentru seriile de timp valutare
- Haos + zgomot : provocari noi, nevoie de abordari si rezultate noi in metodele kernel

# Concluzii

- Cele mai mari sanse de reusita: imbunatatirea modelelor de masini kernel rare
- Necesara utilizarea High Performance Computing pentru rezultate optime
- Abordare interdisciplinara:
  - Procesarea Semnalelor
  - Machine Learning
  - Statistica