

شناسایی یک راکتور همزده توسط شبکه عصبی بهبود یافته

محمودرضا پیشوایی، محمد شاهرخی

دانشگاه صنعتی شریف، دانشکده مهندسی شیمی و نفت

E-mail : pishvaie@sharif.edu

چکیده

غالب الگوریتمهای کنترل تطبیقی، مبتنی بر مدل‌های تجربی و غیرخطی نظیر شبکه‌های عصبی مصنوعی می‌باشد. در عمل باید تعداد پارامترها حتی الامکان کم بوده و در عین حال مدل دقیق باشد. مدل‌سازی مزبور باید بتواند تغییرات مدل را بسرعت تعقیب کرده و همیشه یک تقریب خوب ارائه دهد. در این مقاله به مطالعه توابع پایه موجک در برابر توابع پایه گوسین پرداخته شده است. همچنین ساختار شبکه مزبور با اضافه کردن جملات خطی بهبود داده شده است. نتایج شبیه‌سازی حاکی از آنست که خواص موضعی توابع پایه موجک اعم از زمانی و فرکانسی باعث بهبود قابل توجهی در تخمین رفتار سیستم شده است.


واژه‌های کلیدی: شناسایی سیستم؛ شبکه عصبی مصنوعی؛ توابع پایه موجک؛ کنترل تطبیقی

مقدمه

کاهش خواهد یافت و ممکن است سیستم ناپایدار شود. بنابراین شاید بتوان با یک الگوی ترکیبی مثل اضافه کردن یک جمله خطی به ساختار غیرخطی شبکه از مزایای هر دو روش تقریب (خطی و غیرخطی) بهره گرفت. به بیان دیگر اگر تقریب توابع غیرخطی را با بسط تیلور بیان کنیم، تقریب جمله اول و خطی آن را بعهدہ قسمت خطی ساز شبکه نهادہ و جملات بزرگتر را برای پوشاندن طیف تغییرات بیشتر و انحنای دیفرنسیالی پیچیده تر بعهدہ ساختار غیرخطی بگذاریم. این نحوه ترکیب و بکارگیری شبکه‌های عصبی RBF عمدتاً در صنایع روباتیک مورد توجه قرار گرفته [5] و در صورت بهره‌گیری ایده مزبور در صنایع فرآیندی باید تغییراتی متناسب با سیستم و چارچوب کار در نظر گرفت و پیاده‌سازی نمود، چرا که مساله غالب کنترل در روباتها، تعقب مقدار مقرر (مساله

غالب روش‌های کنترل و تخمین فرآیندهای غیرخطی شامل بکارگیری مدل و تخمین پارامترهای آن براساس تاریخچه اطلاعات ورودی - خروجی است. لذا دقت مدل و دسترس پذیری اطلاعات مزبور نقش عمده‌ای در طراحی و عملکرد کنترلر و تخمین زننده خواهد داشت. استفاده از شبکه‌های عصبی مصنوعی بخاطر جامعیت و بویژه دقت مدل در تخمین نگاشتهای ورودی - خروجی بعنوان یک انتخاب متداول و رایج میباشد [1,2]. با استفاده مقتضی و مناسب از شبکه‌های عصبی میتوان مدل غیرخطی دقیقتر و وسیع‌الطیفی در برابر تغییرات ناگهانی پارامترها و اغتشاشات بزرگ داشت [3,4]. از طرفی مبنای ابزار سنتی طراحی کنترلر بر مدل‌های خطی استوارست و در صورت دورشدن ناگهانی از نقاط عملکرد، کارآیی کنترلر و به تبع آن عملکرد مدار بسته

نشان داده شده است. همانطور که در شکل مشهود می باشد محتوای فرکانسی بطور یکنواخت توزیع شده است و رفتار موضعی ندارد. بطور مثال در یک راکتور پیوسته گرمازا توابع غیرخطی مساله که نیاز به شناسایی دارند در نواحی تبدیل بالا خیلی سریع تغییر میکنند تا در منطقه تبدیل پایین و علت آن وجود تابع نمایی در ثوابت سرعت واکنش های شیمیایی میباشد. از طرفی چون مدل سازی فرآیند بر اساس مدل سازی تجربی میباشد و از ساختار توابع عامل اطلاعاتی در دست نیست، لذا هنگام تطبیق پارامترها (آموزش شبکه) باید به نحوی محل مراکز RBF تغییر داده شود. Canon و Slotine نشان داده اند اگر بجای توابع گوسین از توابع موجک (wavelet) استفاده شود، مکانیسم آموزش سریعتر خواهد بود [6]. یک علت معلوم و مهم آن تغییر محتوای فرکانسی (واریانس) این نوع توابع بوده که بر خلاف توابع گوسین موضعی میباشد.



شکل ۱. رفتار توابع پایه گوسین و موجک (کلاه مکزیک).

آموزش شبکه

شبکه های RBF را می توان بصورت یک شبکه استاندارد سه لایه در نظر گرفت که گره های لایه خروجی مثل یک ترکیب کننده خطی تطبیقی (Adaptive Linear Combiner - ALC) بکار گرفته شده و لایه میانی دارای توابع تحریک خاصی باشند، نظیر توابع گوسین یا توابع موجک. این شبکه ها اولین بار برای نگاهشهای چند بعدی و اصطلاحاً برای میانمایی چندمتغیره بکار گرفته شده

سرو) می باشد، در حالیکه در صنایع فرآیندی نوعاً بصورت حذف اغتشاش (مساله رگولاسیون) می باشد.

شبکه های عصبی مصنوعی

بطور کلی دو نوع تابع تحریک یا تابع پایه در شبکه های عصبی مصنوعی کاربرد دارد، توابع عمومی و موضعی. توابع پایه عمومی نوعاً در گستره وسیعی از مقادیر ورودی گره فعال است، در حالیکه توابع پایه محلی فقط در مقادیر ورودی نزدیک به مرکز تابع، مقدار می پذیرد و در کمی دورتر از مرکز مقداری نزدیک به صفر می گیرند. این نوع توابع محلی برای کاربردهای تطبیقی بسیار مناسب می باشد، چرا که پارامترهای اندکی نیاز به بازتنظیم دارد و آنهم به این خاطرست که اثر ورودیهای محلی، تاثیر زیادی روی بقیه فضای ورودی و همچنین خروجیهای گره های شبکه ندارد. یک کلاس از توابع پایه محلی، توابع پایه شعاعی می باشند. در حالت کلی میتوان این توابع را به شکل زیر برای گره i م بیان نمود:

$$\Phi_i(x) = h(x - \xi_i) \quad (1)$$

بطوریکه ξ_i مرکز تابع (مرکز گره) می باشد. یک فرم مخصوص تابع h ، یک تابع گوسین می باشد:

$$\Phi_i(x) = \exp(-\pi\sigma_i(x - \xi_i)^2) \quad (2)$$

که در آن σ_i معکوس انحراف معیار، $(x - \xi_i)$ آرگومان تابع و معرف میزان دوری از مرکز (شعاع) می باشد. یک عیب توابع گوسین علیرغم خاصیت موضعی آنها، الزام به یکنواختی گره ها در فضای تقریب یا نگاشت تابع می باشد. این بدان معنی است که در عمل لازمست تقریب توابع در برخی نواحی شدیداً تغییر کند ولی در برخی نواحی ورودی ملایمتر تغییر کند. در نتیجه توزیع گره ها (توابع) بازای یک مقدار گره معین نباید متساوی الفاصله باشد. در اصطلاح ریاضی مساله، توابع گوسین دارای فرکانسی عمومی هستند نه موضعی. در شکل ۱ یک تابع گوسین نمونه همراه با یک تابع موجک

شیمیایی غالباً از نوع رگولاسیون است، یعنی همیشه در حول یک نقطه عملیاتی کار میکنند. در نتیجه استفاده از مدل خطی شده (خطی سازی ژاکوبین) برای یک کنترلر مبتنی بر مدل محلی منطقی و متین است. مشکل در اینجاست که اگر یک اغتشاش ناگهانی و بزرگ برای سیستم اتفاق بیافتد و سیستم مجبور به شیفت و کارکرد در یک نقطه عملیاتی جدید باشد، آنگاه مدل خطی و محلی قدیمی ولو آنکه در حال تطبیقی نیز باشد، در این فاصله و حالت گذرا، برای یک کنترل کارآ کفایت نمیکند. لذا ساختار تخمین مدل را بصورت جمع و ترکیب دو جمله خطی و غیرخطی در نظر میگیریم، باین امید که قسمت خطی، ناحیه نزدیک و تقریباً محلی مدل را بپوشاند و قسمت غیرخطی طیف بزرگتر و جملات غیرخطی تر بسط توابع را بپوشاند:

$$f(\underline{X}) \cong \tilde{f}(\underline{X}) = \tilde{f}_{NL}(\underline{X}) + \tilde{f}_L(t) \quad (8)$$

$$g(\underline{X}) \cong \tilde{g}(\underline{X}) = \tilde{g}_{NL}(\underline{X}) + \tilde{g}_L(\underline{X}) \quad (9)$$

بطوریکه $\tilde{f}_{NL}(\underline{X})$ و $\tilde{g}_{NL}(\underline{X})$ توابع غیرخطی، $\tilde{f}_L(t)$ تابعی از زمان و نیز $\tilde{g}_L(\underline{X})$ یک تابع خطی از حالات سیستم میباشد. وقتی سیستم حول یک نقطه عملیاتی کار می کند، آنگاه سیستم غیرخطی را میتوان با تقریب خطی زیر نوشت،

$$\tilde{f}_L(t)x^{(n)}(t) + \tilde{g}_L(\underline{X}) = u(t) \quad (10)$$

در حالیکه بطور کلی و عمومی رفتار مدار باز فرآیند بصورت تقریبی زیر خواهد بود:

$$[\tilde{f}_{NL}(\underline{X}) + \tilde{f}_L(t)]x^{(n)}(t) + \tilde{g}_{NL}(\underline{X}) + \tilde{g}_L(\underline{X}) = u(t) \quad (11)$$

در این پروژه به بررسی عملکرد این نوع تقریب در مقایسه با سایر تقریب های تطبیقی و غیر تطبیقی و انواع توابع پایه میپردازیم، چرا که توابع خطی $\tilde{f}_L(t)$ و $\tilde{g}_L(\underline{X})$ همیشه با ساختار خطی نسبت به ساختار غیرخطی بهتر بیان شده و راحتتر و سریعتر آموزش (تطبیق) داده میشوند. توابع غیرخطی $\tilde{f}_{NL}(\underline{X})$ و $\tilde{g}_{NL}(\underline{X})$ نیز با توابع پایه شبکه

اند ولی بعداً برای مدل سازی فرآیند نیز استفاده شدند. نکته قابل توجه در آموزش این شبکه این است که در صورت معلوم بودن مراکز توابع تحریک میتوان بطور پایدار مقادیر (پارامترها) اوزان شبکه را معلوم کرد. علت آن اینست که ترکیب و ساختار شبکه از نظر ریاضی بصورت خطی پارامتریزه می باشد. از آنجاییکه توابع گوسین دارای میانگین غیرصفر هستند میتوان نداشت تابع را به شکل ترکیب خطی زیر در نظر گرفت:

$$f(x) = \sum \hat{C}_i(t)\Phi_i(x, \xi) \quad (3)$$

ولی با توابع موجک چون دارای میانگین صفر هستند باید یک ترم افزوده (bias) اضافه نمود:

$$f(x) = \sum \hat{C}_i(t)\Phi_i(x, \xi) + \hat{C}(t) \quad (4)$$

بطوریکه $\hat{C}(t)$ تقریبی از ترم افزوده برای تابع نامعلوم بوده و $\hat{C}_i(t)$ یک وزن نمونه از گره i ام در شبکه می باشد...

اضافه کردن ساختار خطی

فرض کنید فرآیند مورد نظر به فرم زیر نمایش داده شود:

$$f(\underline{X})x^{(n)}(t) + g(\underline{X}) = u(t) \quad (5)$$

بطوریکه $u(t)$ متغیر کنترل کننده (ورودی) فرآیند و $\underline{X}(t)$ بردار حالت سیستم، $\underline{X}(t) = [x(t) \dot{x}(t) \dots x^{(n-1)}(t)]$ نیز تابعی غیرخطی از بردار حالات میباشد. به منظور کنترل هر چه دقیقتر و مبتنی بر مدل باید توابع $f(\underline{X})$ و $g(\underline{X})$ حتی الامکان بطور دقیق تخمین زده شوند. این توابع میتوانند بصورت جمع وزنی توابع پایه زیر بیان شوند:

$$\tilde{f}(\underline{X}) = \sum \alpha(t)\Phi(\underline{X}, \xi) \quad (6)$$

$$\tilde{g}(\underline{X}) = \sum \beta(t)\Phi(\underline{X}, \xi) \quad (7)$$

بطوریکه $f(\underline{X})$ و $g(\underline{X})$ مقادیر ضرایب وزنی توابع پایه $\Phi(\underline{X}, \xi)$ میباشد.

قبل از اضافه کردن ساختار خطی بهتر است ابتدا به انگیزه و ایده اصلی این عمل پرداخته شود. کنترل فرآیندهای

ژاكت ($x_{2,i}$). متغير كنترل كننده (ورودی) حلقه كنترل دما نيز شدت جريان ميباشد.

نتايج شبیه سازی

برای محك و مقایسه نحوه تقریب توابع پایه مختلف، مدل طراحی شناساگر را بصورت گسسته (با زمان نمونه برداری معادل 0.01 واحد زمانی) و خطی نسبت به متغير كنترل كننده در نظر گرفته و برای تحريك سیستم از ورودیهای غنی شبه تصادفی استفاده می کنیم. مضافاً اینکه برای قانون تطبیق از روش حداقل مربعات با بهره اولیه 10I استفاده شده است که I ماتریس واحد است.

نمونه اول - فرآیند را بصورت فضای حالت زیر در نظر گرفته و توابع غیرخطی و را بصورت ترکیب خطی از توابع پایه گوسین دو بعدی لحاظ می کنیم. وضوح و تعداد مراکز متغير حالت اول (دما) بصورت پنج تایی و متغير حالت دوم (غلظت) بصورت چهارتایی و هر دو متساوی الفاصله در نظر گرفته شدند، لذا تعداد پارامترهای تطبیق شده معادل 42 عدد (هر کدام 21 تا) محاسبه می شود.

$$\begin{cases} x_1(k) = f_1(x_1(k-1), x_2(k-1)) + \alpha^L u(k-1) \\ \quad = \phi^T \theta_1 \\ x_2(k) = f_2(x_1(k-1), x_2(k-1)) + \beta^L u(k-1) \\ \quad = \phi^T \theta_2 \end{cases} \quad (16)$$

$$\phi^T = [\Phi_1 \quad \Phi_2 \quad \dots \quad \Phi_N \quad u(k-1)] \quad , \quad (17)$$

$N = 1, 2, \dots, 20$

$$\begin{cases} \theta_1^T = [\alpha_1 \quad \alpha_2 \quad \dots \quad \alpha_N \quad \alpha^L] \\ \theta_2^T = [\beta_1 \quad \beta_2 \quad \dots \quad \beta_N \quad \beta^L] \end{cases} \quad (18)$$

با تحريك سیستم مطابق شکل 2، شناساگر فرآیند عمل کرده و تطبیق پارامترها انجام می شود. برای سه اغتشاش غلظت و دمای جريان ورودی و دمای ژاكت، فرکانس تغییر بزرگتری نسبت به ورودی متغير كنترل كننده در نظر گرفتیم. در شکل 3 (قسمت فوقانی)، نحوه تغییر بهره شناساگر بصورت trace ماتریس بهره نمایش داده شده

عصبی بیان خواهند شد و آموزش خواهند دید. برای سادگی و نمایش بهتر فرض کنید با یک سیستم درجه دو کار میکنیم، در نتیجه مدل فرآیند را بصورت زیر باید بیان کنیم:

$$[\tilde{f}_{NL}(x, \dot{x}) + \tilde{f}_L(t)]\ddot{x}(t) + \tilde{g}_{NL}(x, \dot{x}) + \tilde{g}_L^{(I)}(t)x(t) + \tilde{g}_L^{(II)}(t)\dot{x}(t) = u(t) \quad (12)$$

توابع $\tilde{f}_{NL}(x)$ و $\tilde{g}_{NL}(x)$ را میتوان بصورت یک شبکه عصبی تطبیقی تقریب زد:

$$\tilde{f}_{NL}(x, \dot{x}) = \sum \hat{\alpha}(t)\Phi(x, \dot{x}, \xi_1, \xi_2) \quad (13)$$

$$\tilde{g}_{NL}(x, \dot{x}) = \sum \hat{\beta}(t)\Phi(x, \dot{x}, \xi_1, \xi_2) \quad (14)$$

مقادیر پارامترهای $\hat{\alpha}(t)$ و $\hat{\beta}(t)$ با استفاده از یک قانون تطبیق و تعریف یک خطا (خطای فیدبک و یا خطای تخمین) بهنگام خواهند شد. توابع $\tilde{g}_L^{(I)}(t)$ و $\tilde{g}_L^{(II)}(t)$ نیز از ژاکوبین تابع حالات بدست می آیند.


شبیه سازی دینامیکی فرآیند

برای بررسی عملکرد توابع پایه مختلف شبکه عصبی از یک CSTR نمونه با مدل زیر استفاده شده است،

$$\begin{cases} \dot{x}_1 = -2k_0 \exp(-E/Rx_2)x_1^2 + (x_{1,i} - x_1)F/V \\ \dot{x}_2 = 2Hk_0 \exp(-E/Rx_2)x_1^2 / \rho C_p - UA(x_2 - x_{2,j})/V\rho C_p + (x_{2,i} - x_2)F/V \end{cases} \quad (15)$$

بطوریکه بردار حالات عبارتند از، غلظت واکنشگر (x_1) و دمای راکتور (x_2). معادله اول از روی بیلان جرم و معادله دوم بر اساس بیلان انرژی نوشته شده اند. پارامترهای $F, V, E, k_0, R, \rho, C_p, H, U, A$ ، به ترتیب عبارتند از شدت جريان خوراك، حجم راکتور، انرژی اکتیواسیون، ثابت سرعت واکنش، ثابت گازها، دانسیته، ظرفیت گرمایی ویژه، انتالی واکنش، ضریب انتقال حرارت جمعی و سطح انتقال حرارت. اغتشاشات سیستم عبارتند از غلظت ورودی ($x_{1,i}$)، دمای ورودی ($x_{2,i}$) و دمای ورودی مبرد به


تعداد پارامتر تطبیقی بیشتر و به تبع آن بار محاسباتی بیشتر بدست آوردیم.



شکل ۴ - تغییرات trace بهره ماتریس (نمودار فوقانی)،

تغییرات متغیرهای حالت (نمودارهای میانی و پایین) برای مورد

دوم.




شکل ۵ - تغییرات trace بهره ماتریس (نمودار فوقانی)،

تغییرات متغیرهای حالت (نمودارهای میانی و پایین) برای مورد


سوم.

نمونه سوم - برای کاهش بار محاسباتی از توابع پایه موجک استفاده می کنیم، چرا که حدس می زنیم رفتار دمایی سیستم بخاطر وجود توابع نمایی (فرضیه آرنیوس) باید همراه با تغییرات موضعی فرکانسی باشد. به همین خاطر همان شرایط نمونه شبیه سازی اول را ولی با توابع

است و در شکل میانی و پایین، نمودارهای تخمین غلظت و دما به همراه مقادیر واقعی آنها نمایش داده شده است.



شکل (۲) - نحوه اعمال ورودی به فرآیند نمونه.




شکل ۳ - تغییرات trace بهره ماتریس (نمودار فوقانی)،

تغییرات متغیرهای حالت (نمودارهای میانی و پایین) برای مورد اول.

نمونه دوم - با توجه به نتایج اخیر بویژه خطای زیاد در متغیر حالت دما، بنظر میرسد مراکز گره ها باید نزدیکتر به هم باشند. لذا تعداد گره ها را برای غلظت همان ۵ تا ولی برای دما به ۸ تا افزایش دادیم. با این کار تعداد پارامترها به ۸۲ عدد می رسد. اگر نتایج شبیه سازی را تکرار کنیم به نمودارهای مندرج در شکل ۴ می رسیم. همانطور که مشاهده می شود دقت تقریب بسیار بهتری البته به بهای

های کمتر از خود نشان می دهند. علت عمده این اثر بویژه در متغیر حالت دما، وجود جملات نمایی می باشد. بعلاوه، از آنجاییکه کنترل فرآیندهای شیمیایی غالباً از نوع رگولاسیون (حذف اغتشاش) است، تقریب خطی مدل در مناطق نزدیک به شرایط عملیاتی، تخمین نسبتاً خوبی از رفتار دینامیکی بدست دهد. لذا، این امید می رود اگر شبکه عصبی RBF با توابع پایه موجک علاوه بر وجود جمله افزوده دارای جملات خطی نسبت به متغیرهای حالت سیستم نیز باشد، تقریب بهتر، جامعتر و آموزش (تطبیق) سریعتری داشته باشیم. این مورد نیز امتحان شد و مطابق انتظار نتایج بسیار بهتری حاصل گردید. کار آتی نگارندگان بررسی نحوه شناسایی سیستم در حالت مدار بسته می باشد.



شکل ۶ - تغییرات trace بهره ماتریس (نمودار بالایی)، تغییرات متغیرهای حالت (نمودارهای وسط و پایین) برای مورد چهارم.

پایه موجک تکرار می کنیم. نمودارهای مربوطه در شکل ۵ نشان داده شده است. نتایج حاکی از توافقی رضایتبخش و قابل انتظار بویژه تقریب متغیر حالت دما می باشد

نمونه چهارم - برای مورد آخر، ترم های خطی را اضافه کرده و شبیه سازی را تکرار میکنیم. بدین منظور معادله شناساگر را به فرم زیر در نظر می گیریم:

$$\begin{cases} x_1(k) = f_1(x_1(k-1), x_2(k-1)) + \alpha_1^L x_1(k-1) + \alpha_2^L x_2(k-1) + \alpha^L u(k-1) = \phi^T \theta_1 \\ x_2(k) = f_2(x_1(k-1), x_2(k-1)) + \beta_1^L x_1(k-1) + \beta_2^L x_2(k-1) + \beta^L u(k-1) = \phi^T \theta_2 \end{cases} \quad (19)$$

$$\phi^T = [\Phi_1 \quad \Phi_2 \quad \dots \quad \Phi_N \quad 1 \quad x_1(k-1) \quad x_2(k-1) \quad u(k-1)], \quad (20)$$

$$N = 1, 2, \dots, 20$$

$$\begin{cases} \theta_1^T = [\alpha_1 \quad \alpha_2 \quad \dots \quad \alpha_N \quad \alpha_{bias} \quad \alpha_1^L \quad \alpha_2^L \quad \alpha^L] \\ \theta_2^T = [\beta_1 \quad \beta_2 \quad \dots \quad \beta_N \quad \beta_{bias} \quad \beta_1^L \quad \beta_2^L \quad \beta^L] \end{cases} \quad (21)$$

ذکر این نکته لازمست که تعداد پارامترها همچنان کم می باشد و فقط برای هر متغیر حالت دو پارامتر اضافی در نظر گرفته ایم. نتایج شبیه سازی در شکل ۶ نمایش داده شده است. همانطور که مشاهده می شود تقریب مزبور بسیار دقیق عمل کرده و در همان ابتدای کار شبکه عصبی با توابع پایه موجک و اضافه شدن جملات خطی سرعت آموزش دیده است.

بحث و نتیجه گیری

در این بررسی تحقیقاتی به تاثیر توابع پایه (گوسین کلاسیک و توابع موجک) در نحوه تقریب زدن رفتار دینامیکی یک راکتور همزده پرداخته شد. مشاهده شد توابع موجک نتایج بسیار بهتری نسبت به توابع همگن و یکنواخت در فرکانس تغییر (نظیر گوسین) به رغم گره

تشکر و قدردانی

بدینوسیله از حمایت‌های مالی معاونت محترم پژوهشی دانشگاه صنعتی شریف قدردانی می‌شود.

مراجع

1. Bhat N., McAvoy T., Use of Neural Networks for dynamic Modeling and Control of Chemical Process Systems, Computers in Chemical Engineering, 14, 1990, pp 573-583.
2. Thompson M., Kramer, Modeling Chemical Processes Using Prior Knowledge and Neural Networks, AIChE Journal, 40(8), 1994, pp 1328-1340.
3. Schenker B., Agarwal M., State Prediction for Chemical Reactors Using Feedback Neural Networks, Proceedings of DYCORD+92 Conference, IFAC Dynamics and Control of Chemical Reactors, Maryland, USA, 1992.
4. Seborg D.E., Experience with Nonlinear Control and Identification Strategies, Control 94, 1994, pp 879-886.
5. Sanner R., Slotine J.j-E., Gaussian Networks for Direct Adaptive Control, IEEE Transactions on Neural Networks, 3(6), 1992, pp 837-863.
6. Cannon M., Slotine J.j-E., Space Frequency Localized Basis Function Networks for Nonlinear system Estimation and Control, Neurocomputing, 9(3), 1995, pp 293-342.