# پایش سیستم و عیب یابی

علی چائی بخش

فصل اول

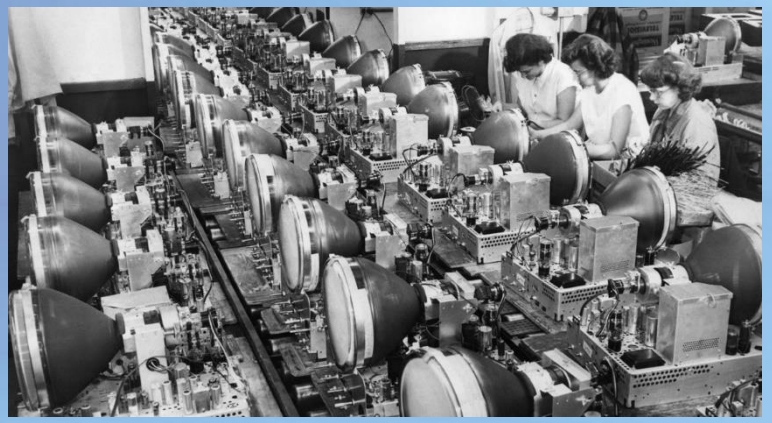
# مقدمه

# مقدمه

- از ۱۹۶۰ اتوماسیون صنعتی تاثیر بسیار زیادی بر روی عمکرد سیستم ها و فرآیندها داشته است.
- این توسعه اتوماسیون سبب افزایش تقاضا برای بهبود کارایی فرآیندها و کیفیت محصولات شد.
- لازمه چنین سیستم هایی کاهش وابستگی آن به وجود اپراتور است.

1960





# مقدمه

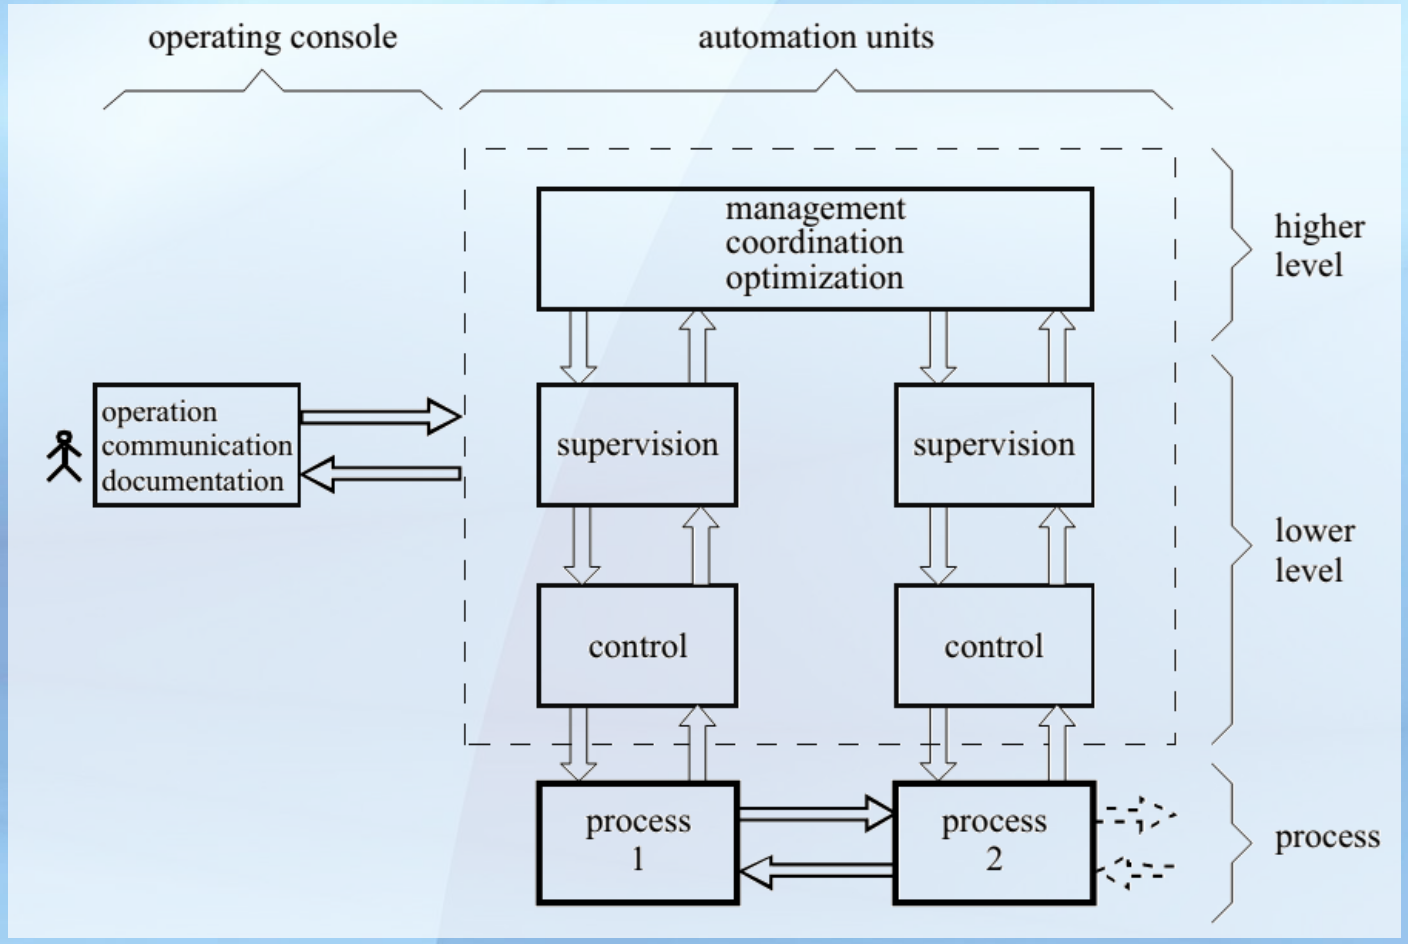
- با توسعه سیستم های الکترونیکی و میکروکنترلرها در ۱۹۷۰ استفاده از سیستمهای اتوماسیون پیشرفته به سرعت افزایش یافت.
- مهمترین مساله در این سیستم های پیچیده برقراری ارتباط، کنترل، نظارت، پایش، عیب یابی و بازآرایی سیستم با توجه به شرایط کاری است.



1970

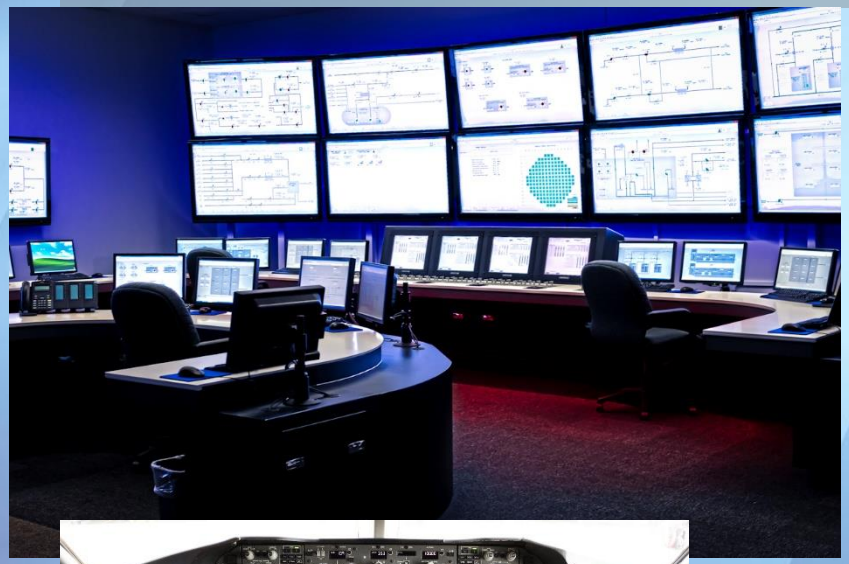
# مقدمه

- شمای ساده از اتوماسیون یک سیستم



# مقدمه

- سیستم های کنترل و نظارت

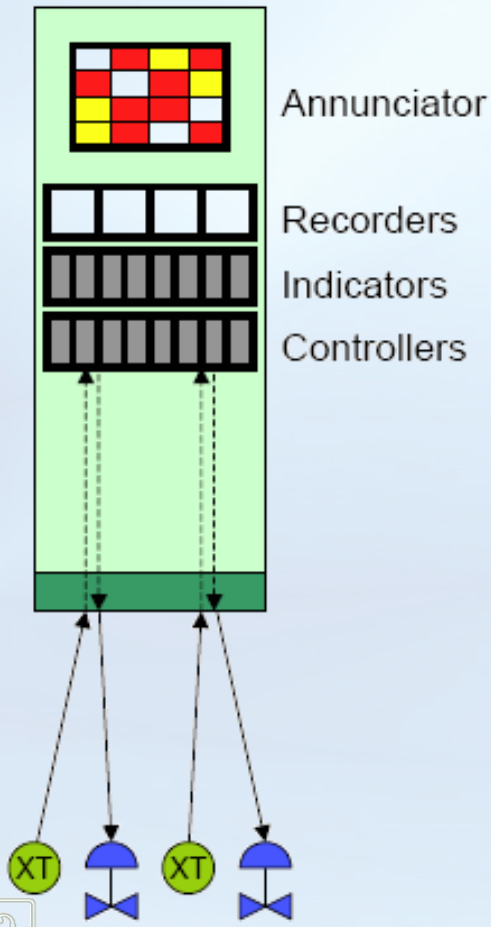








# مقدمه




- ساختارهای کنترلی:
- Direct Digital Control (DDC)

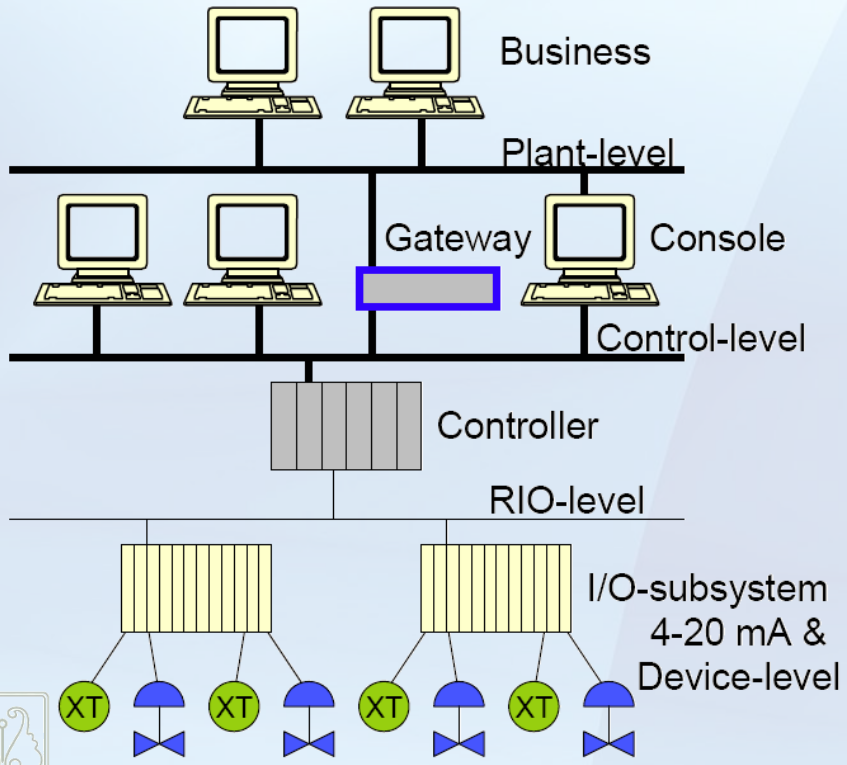
– این ساختار اولین سیستم کامپیوتر کنترل صنعتی بود که در پالایشگاه Port Arthur تگزاس آمریکا در ۱۹۵۹ بکار گرفته شد.

- RW-300 (Ramo-Wooldridge Co)

1974
University of Guilan

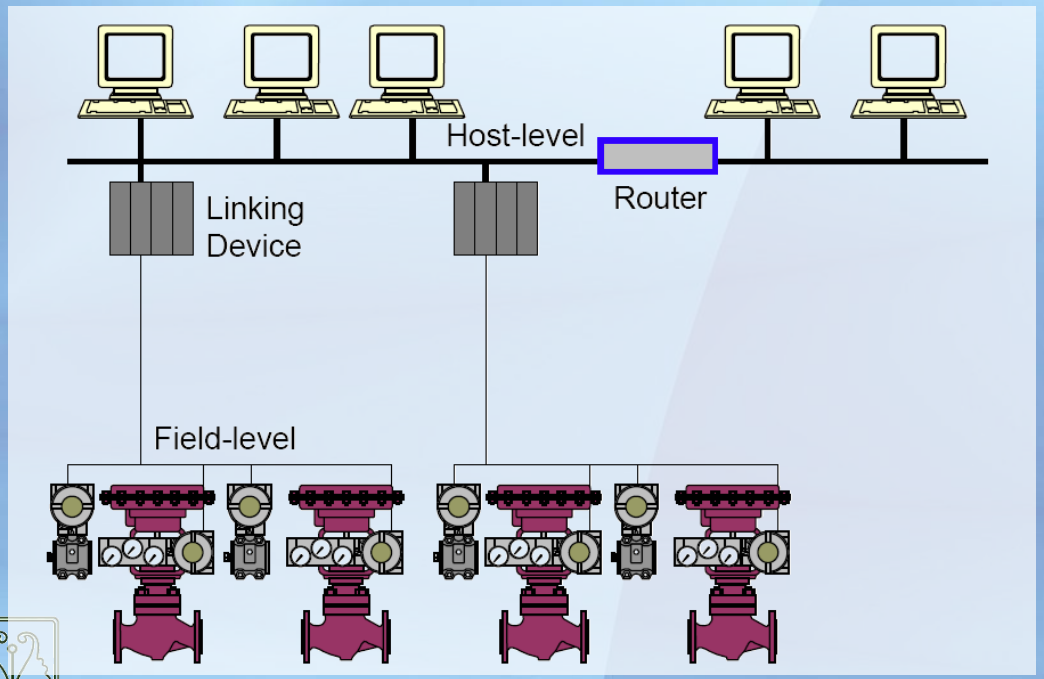
# مقدمه

- Distributed Control System (DCS)
  - ساختار سیستم کنترل گسترده در ۱۹۷۵ معرفی شد.
  - این کنترل به شکل ساختار چندلایه به صورت نشان داده در شکل است.



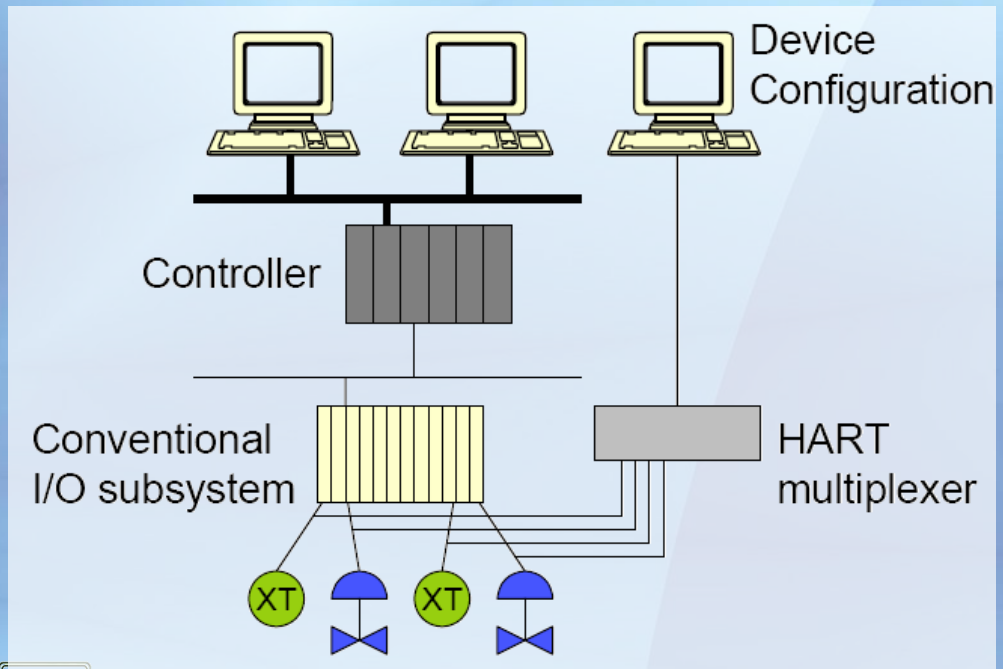
# مقدمه

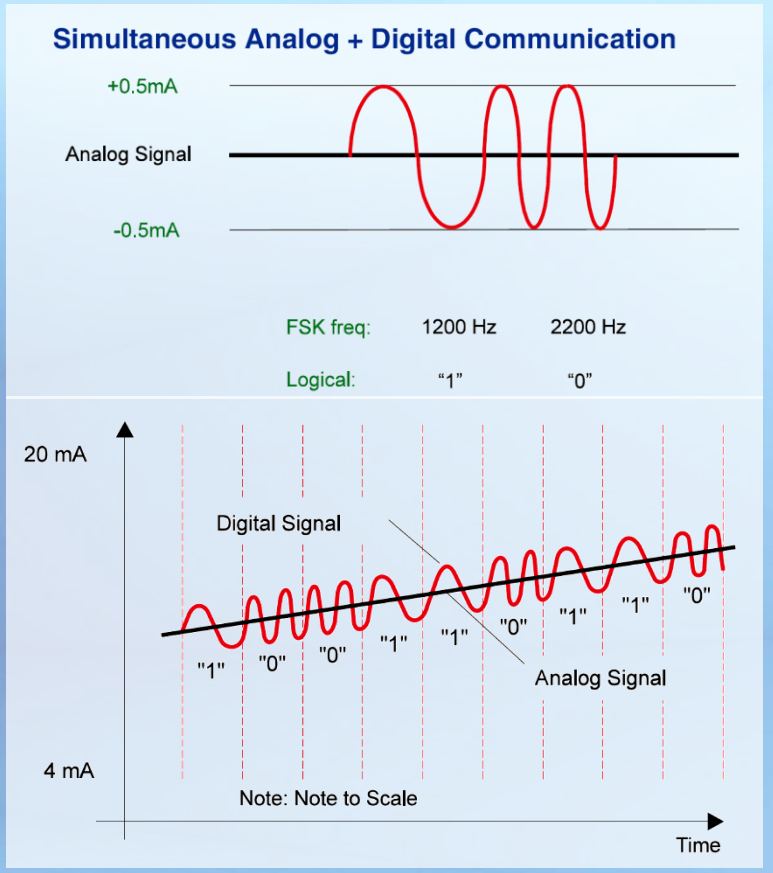
- Fieldbus Control System (FCS)
  - این ساختار در حدود ۱۹۸۸ ارائه شد که ارتباط تجهیزات ابزار دقیق، سنسورها، کنترلرها و عملگرها در سطح فیلد و سیستم های کنترلی نظارتی و کامپیوترها در سطح هاست است.



# مقدمه

- Highway Addressable Remote Transducer
  - یک پروتکل برای ارسال همزمان سیگنالهای آنالوگ و دیجیتال است.



# مقدمه

- Programmable Logic Controller (PLC)
  - کنترلرهای برنامه پذیر منطقی بر اساس لاجیک یا منطق باینری عمل می کنند









# مقدمه

- ساختار چندلایه سیستم نظارت، کنترل و جمع آوری اطلاعات SCADA و کنترل فرآیند صنعتی ICS

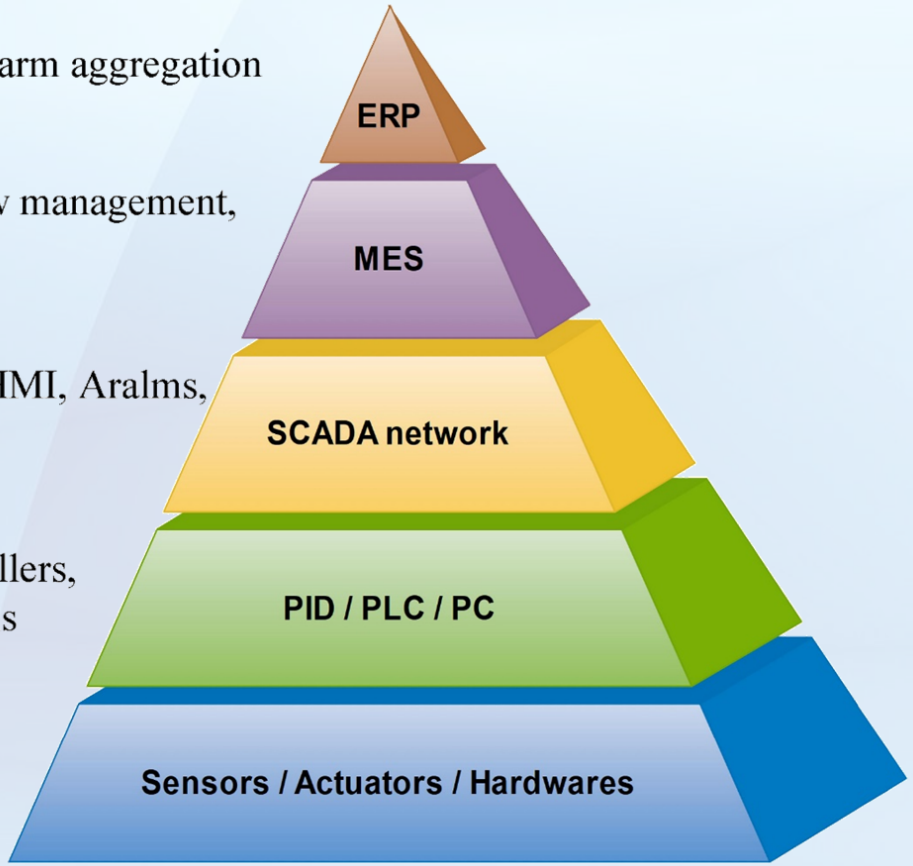
Layer 4
Enterprise systems: ERP, SAP, Alarm aggregation

Layer 3
Operation management: work flow management, OPC client and servers

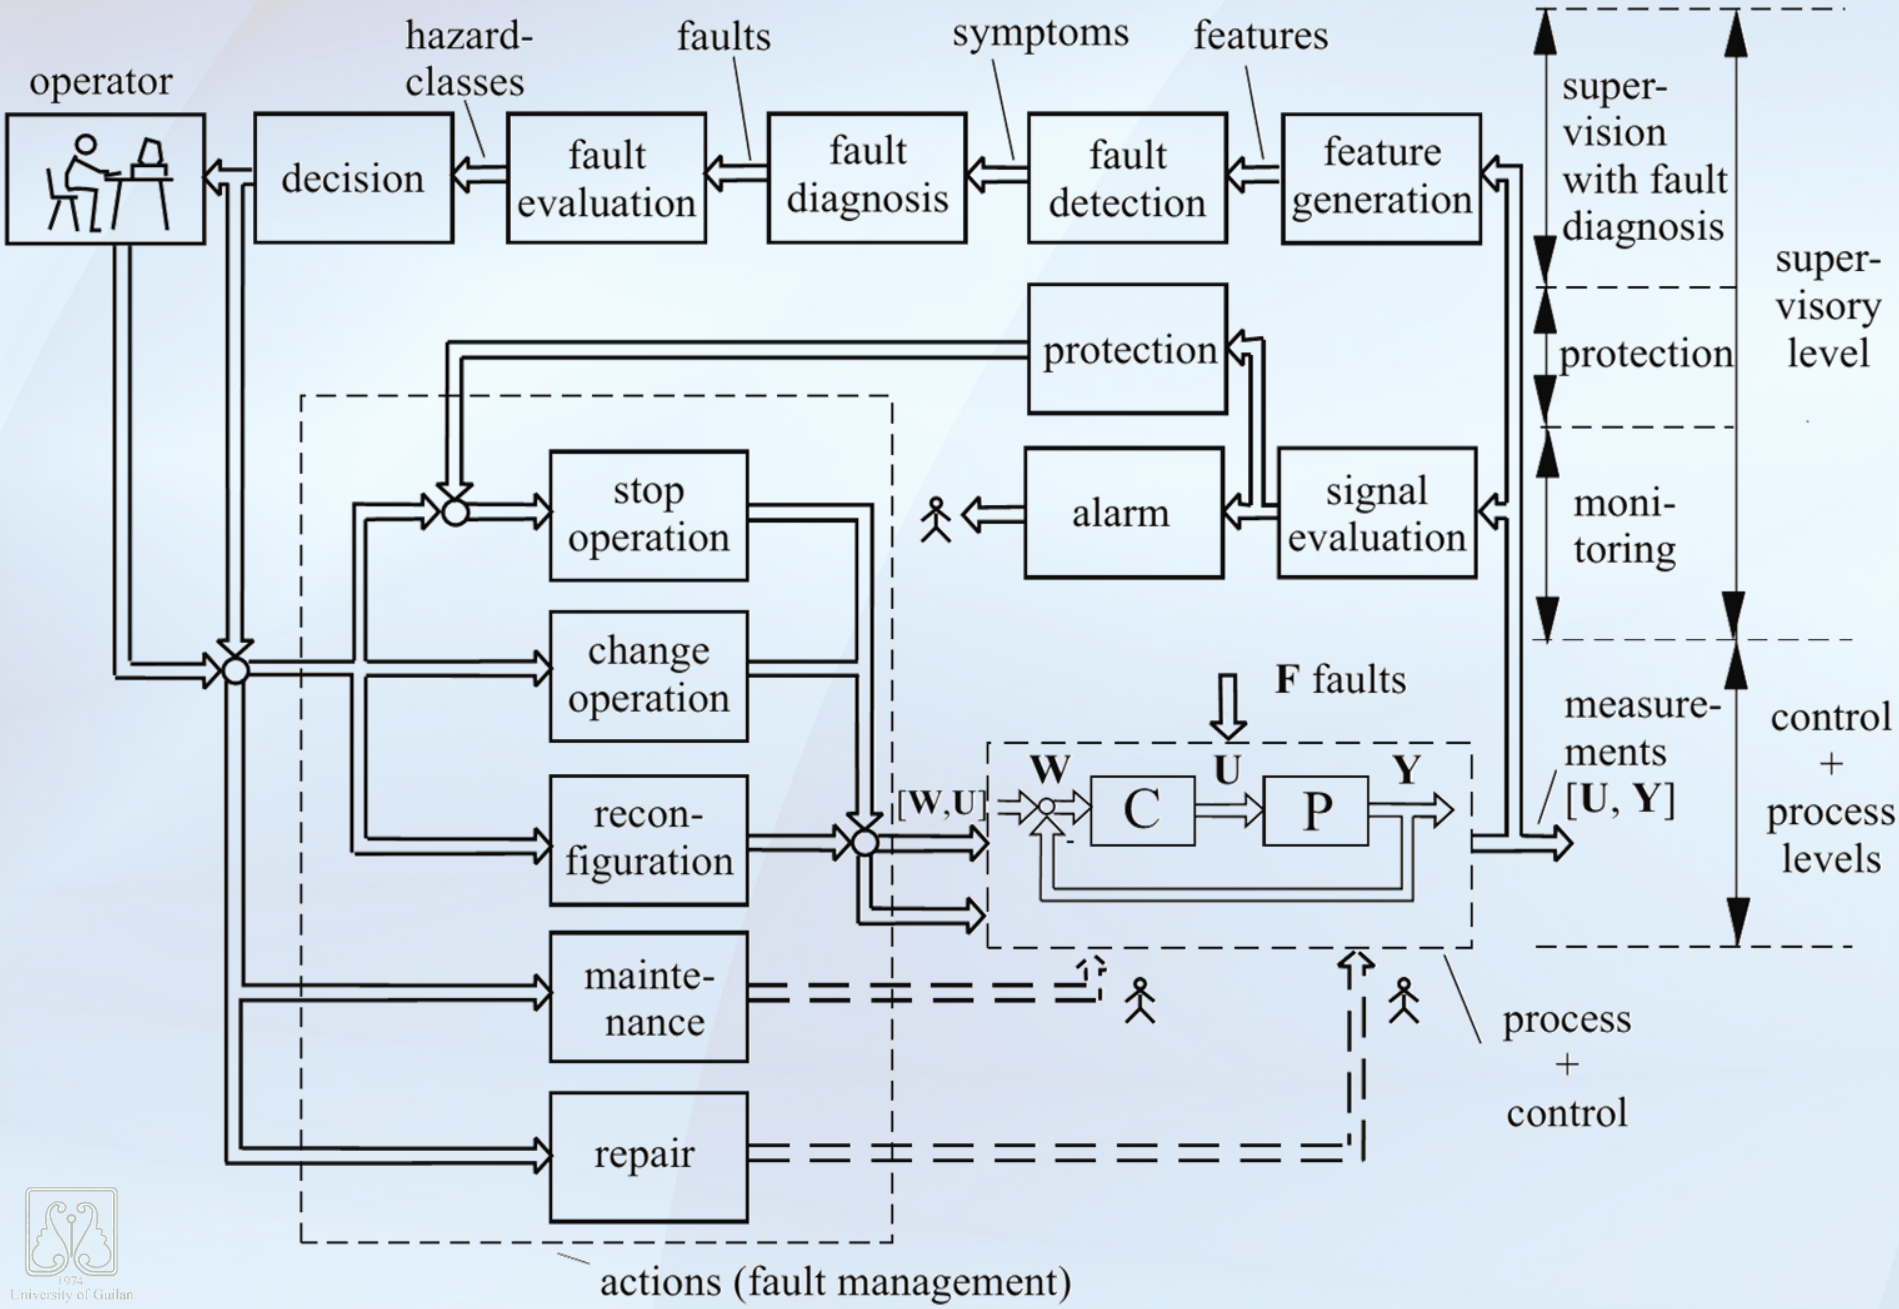
Layer 2
Supervisory control: display and HMI, Aralms, safety and fault diagnosis systems

Layer 1
Basic process control: field controllers, advanced controller, safety systems

Layer 0
Process field: sensors, actuators, transmitters and utilities



# ساختار کنترل نظارتی همراه با عیب یابی




1974 University of Guilan

فصل دوم

# مفاهیم اولیه در پایش وضعیت

# مفاهیم اولیه

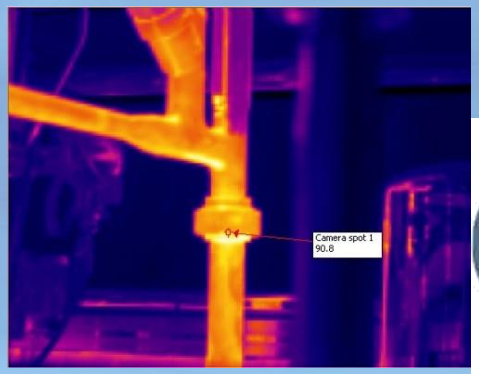
- مفاهیم مختلفی همانند عیب، خرابی، ایمنی، قابلیت اطمینان، و تحمل پذیری عیب در حوزه های مختلف فناوری مورد استفاده قرار می گیرند که اصولا ساختار و روش یکسانی را بیان نمی کنند.
- بر این اساس فدراسیون بین المللی کنترل اتوماتیک:

The IFAC technical committee of Safe Process

سعی کرده تا تعریف واحدی برای این مفاهیم ارائه کند.

# مفاهیم اولیه

- عیب (Fault): انحراف غیر مجاز حداقل یکی از پارامترهای سیستم از مقدار معمول، قابل قبول و یا استاندارد
  - تشخیص وجود عیب بخصوص در مراحل ابتدایی آن معمولا به سادگی قابل تشخیص نیست.
  - تشخیص زودهنگام عیب اهمیت زیادی در کاهش هزینه های تعمیر و نگهداری دارد.






# مفاهیم اولیه

- عیب به معنی انحراف غیر قابل پیش بینی متغیر معیوب از مرزهای یک منطقه تحمل پذیری یا Threshold است.
- عیب یا Fault یک شرایط غیرعادی است که عملکرد و توانایی یک سیستم برای انجام مسولیت تعریف شده برای آن کاهش یافته و یا از بین برود.
- عیب یک سیستم چه در حال کار بوده و یا این که نباشد وجود خواهد داشت.
- عیب می تواند عملکرد اصلی یک سیستم را تحت تاثیر قرار ندهد (مثل پیکسل سوخته یک نمایشگر، خم شدگی شفت،...)
- یک عیب می تواند آغاز کننده شکست کامل یا عملکرد بد سیستم شود.

# مفاهیم اولیه

- انواع مختلفی از عیب وجود دارد:
  - عیب طراحی
  - عیب تولید
  - عیب مونتاژ
  - عیب کارکرد عادی (استهلاک)
  - عیب بکارگیری نادرست (بار اضافی)
  - عیب تعمیرات
  - عیب سخت افزاری
  - عیب نرم افزاری
  - عیب کاربری (عامل انسانی)

# مفاهیم اولیه



- شکست (Failure): قطع دائم توانایی سیستم در انجام یک عملکرد خواسته شده در شرایط کاری معین








# مفاهیم اولیه

- شکست به معنی از بین رفتن (termination) عملکرد یک سیستم در انجام یک وظیفه مشخص است.
- شکست یک حادثه یا event است.
- شکست می تواند حاصل یک یا چند عیب باشد.
- شکست معمولا می تواند در آغاز یک عملکرد (مثل پرتاب موشک) یا به صورت افزاینده با تحت تنش قرار گرفتن سیستم ایجاد شود.

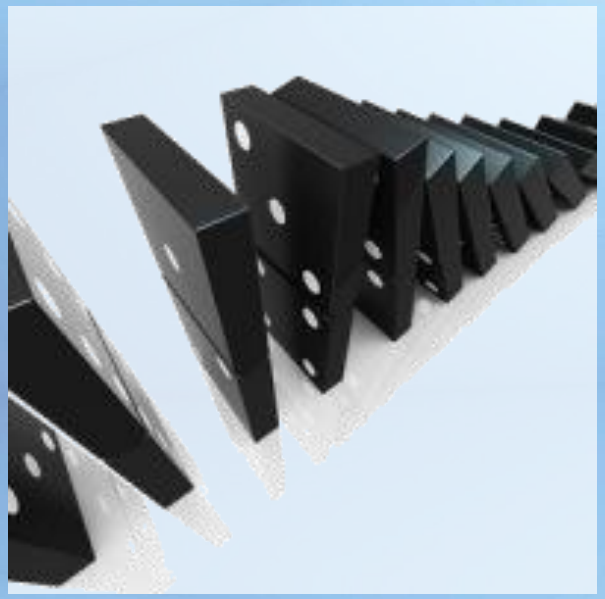
# مفاهیم اولیه

- انواع مختلف شکست وجود دارد:
  - از نظر تعداد: یک یا چند شکست

* معمولا شکست های چندتایی به دلیل گسترش شکست در یک سیستم اتفاق می افتند. به چنین پدیده ای Domino effect گویند.

**Japan - Fukushima Daiichi nuclear power unit (March 11, 2011)**





# مفاهیم اولیه

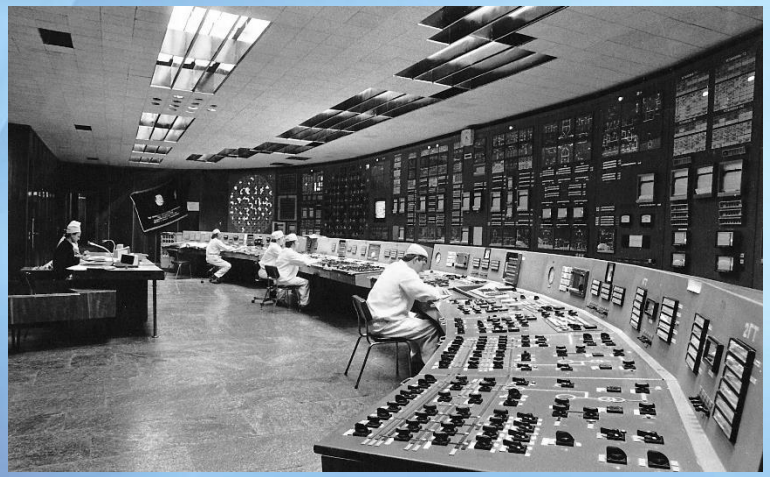
– از نظر قابلیت پیش بینی

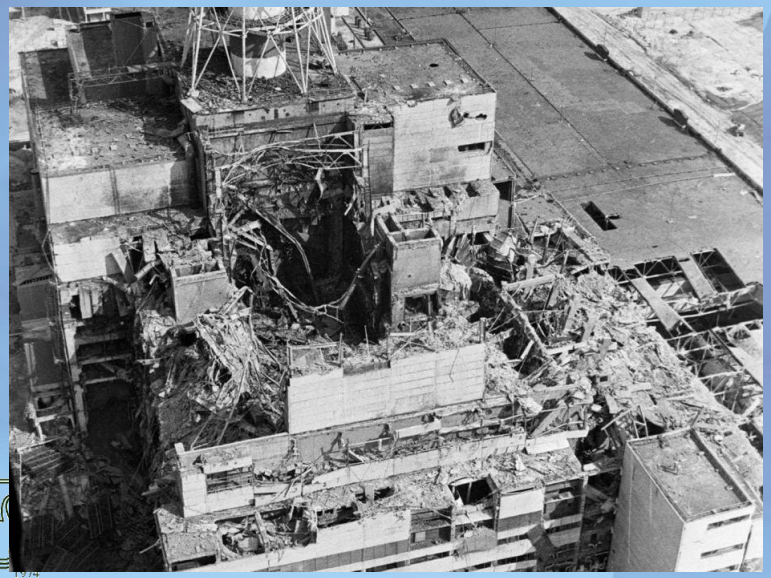
- شکست های تصادفی (Random failures): غیرقابل پیش بینی، به عنوان مثل از نظر آماری غیروابسته به زمان عملکرد یا سایر شکست ها

- شکست های قطعی (Deterministic failures): قابل پیش بینی با توجه به شرایط خاص

- شکست های سیستماتیک (Systematic) یا علّی (Casual): وابسته به یک شرایط معین

# مفاهیم اولیه



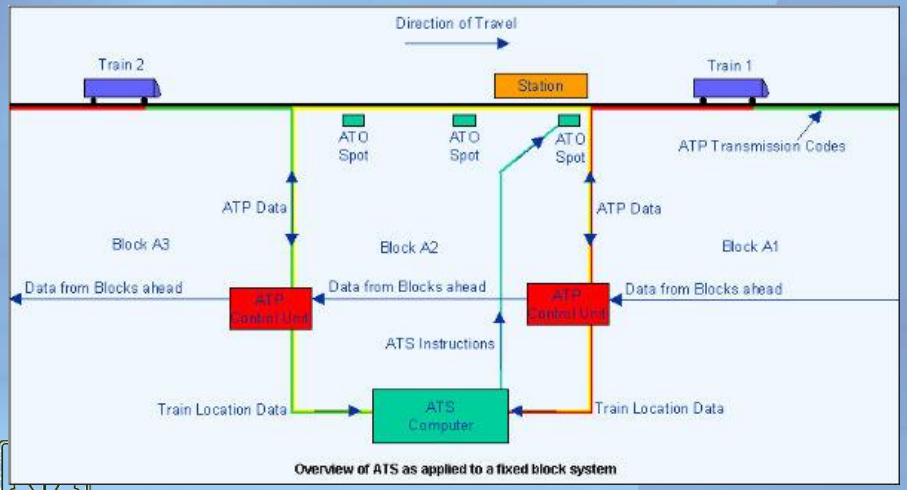


- حادثه چرنوبیل (Chernobyl) در پرپیات (Prypyat)
- April 26, 1986
- عدم توانایی سیستم در شناسایی شرایط غیر عادی (Abnormal)
- عدم وجود دستورالعمل مناسب برای اپراتور برای برخورد با شرایط ناپایداری راکتور

# مفاهیم اولیه



- حادثه قطار سمنان، ۱۳۹۵ (2016) : نمونه ای عیب در سیستم مانیتورینگ و نظارت
- عدم دریافت سیگنال از سنسورها
- اخطار کاذب متعدد
- بی تفاوت شدن اپراتور نسبت به اخطارها
- عدم توانایی در ارزیابی شرایط
- تصمیم نادرست در زمان بحران



Overview of ATS as applied to a fixed block system

# مفاهیم اولیه

- بد عمل کردن (Malfunction): نوسان غیر معمول سیستم در انجام کامل عملکرد خواسته شده.



بد عمل کردن یک سیستم می تواند یک دلیل غیرمعمول داشته باشد!!

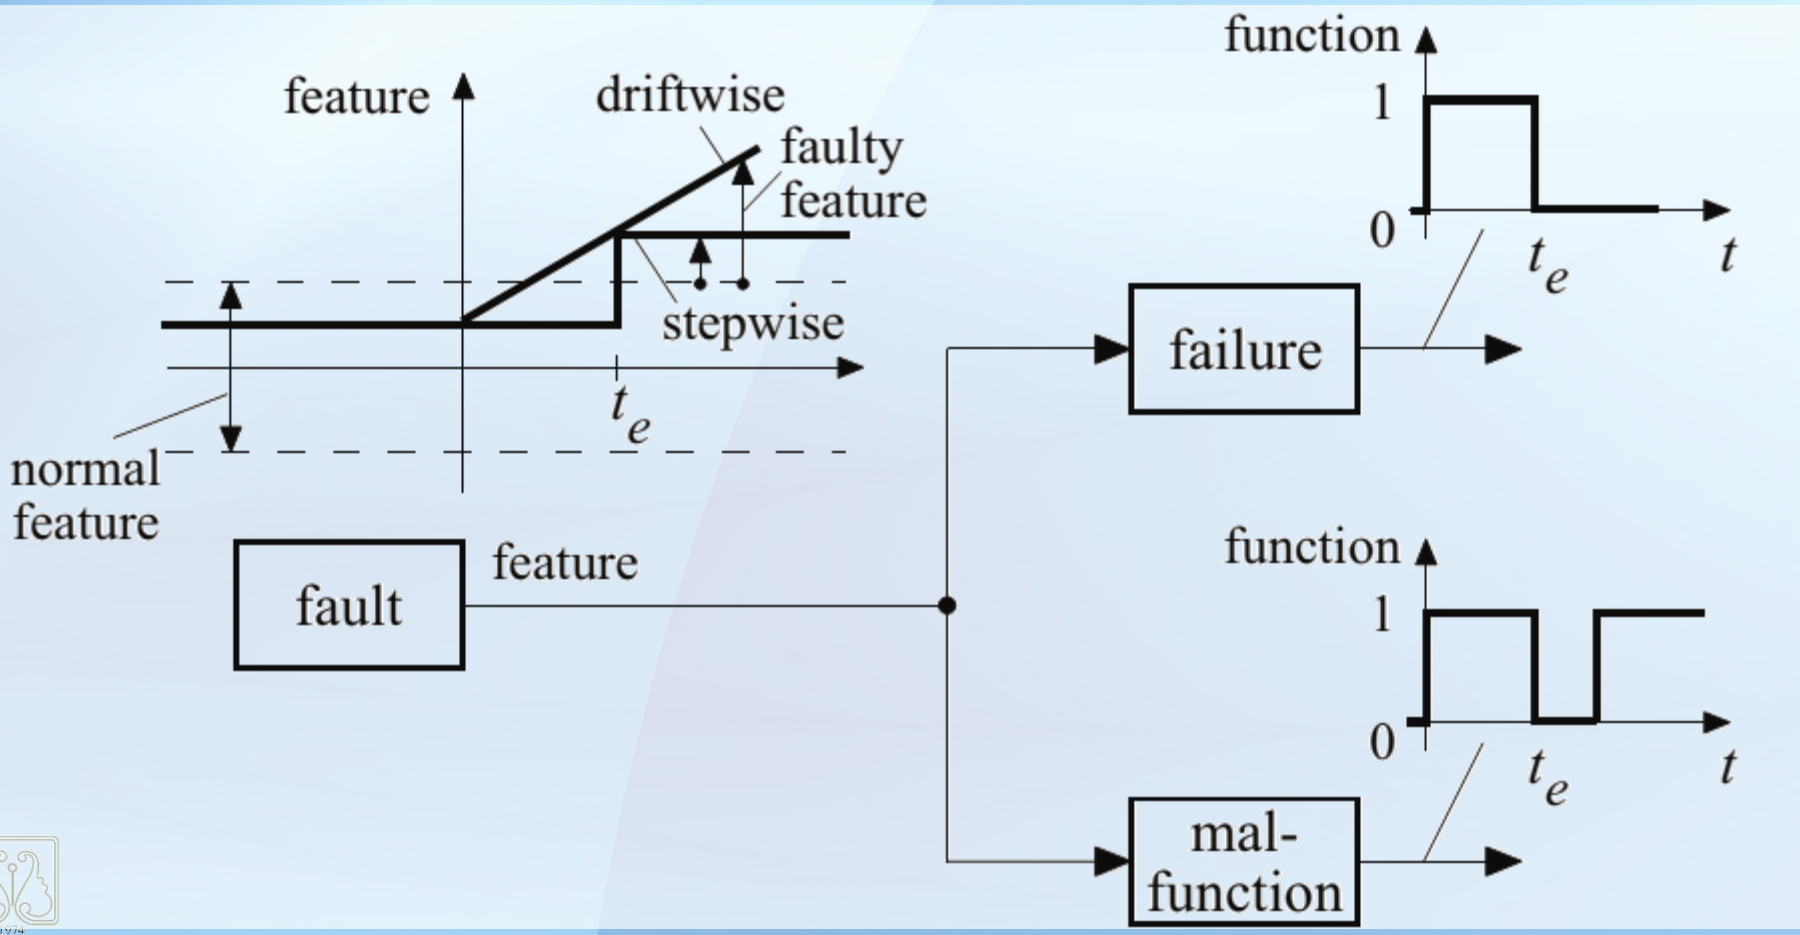


# مفاهیم اولیه

- بد کار کردن به صورت موقت عملکرد سیستم را مختل می کند.
- بد کار کردن یک حادثه یا event است.
- بد کار کردن نتیجه یک یا چند عیب است.
- بد کار کردن معمولا می تواند در آغاز یک عملکرد یا به صورت افزاینده با تحت تنش قرار گرفتن سیستم ایجاد شود.

# مفاهیم اولیه

- تفاوت بین شکست (Failure) و بدکارکردن (Malfunction)



# مفاهیم اولیه

- قابلیت اطمینان (Reliability): توانایی یک سیستم برای انجام عمل مشخص، تحت شرایط مشخص، در یک کاربرد مشخص و بر یک بازه زمانی مشخص.

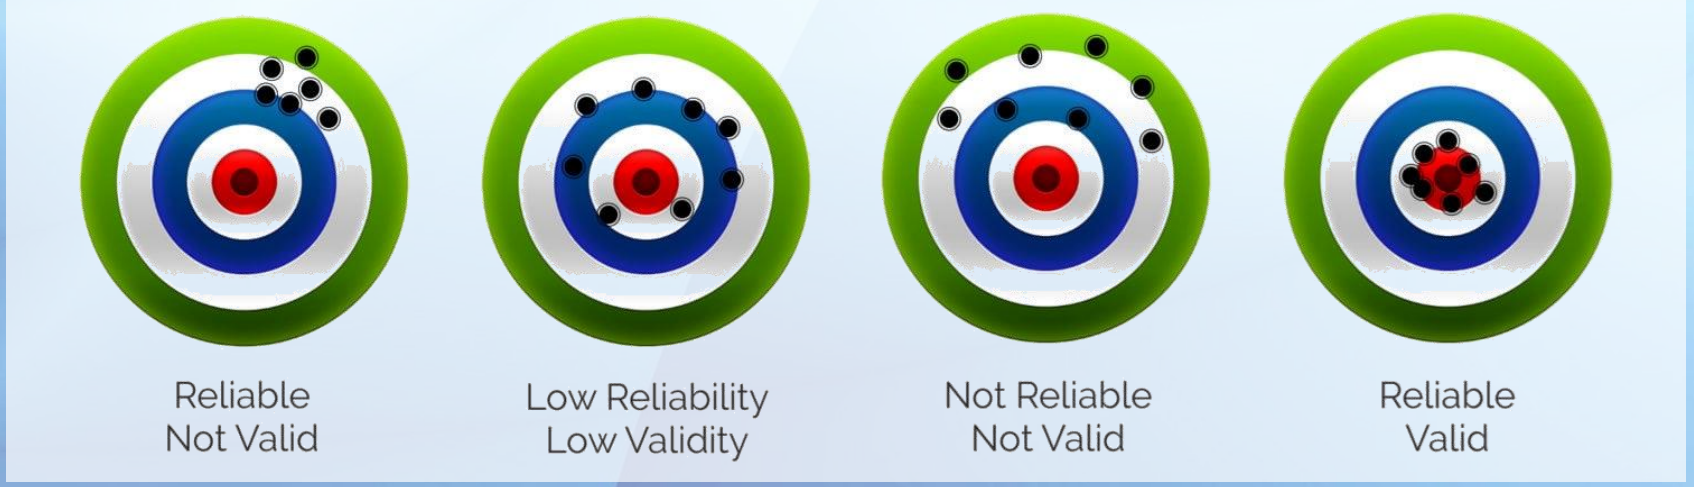
– یک معیار برای اندازه گیری قابلیت اطمنیان، متوسط زمان برای شکست (MTTF) است:

– Mean Time to Failure = $1 / \lambda$

که در آن $\lambda$ نرخ شکست ها در واحد زمان است.

# مفاهیم اولیه

- به صورت خلاصه: توانایی انجام یک فعالیت در بازه زمانی مشخص



# مفاهیم اولیه

- تخمین قابلیت اطمینان:

$$R(t) = \frac{n(t)}{N} = \frac{\text{failure free elements}}{\text{number of all elements at the begin of operation}}$$

– در این صورت عدم اطمینان یک سیستم Q(t) به شکل زیر تعریف می شود:

$$Q(t) = n_f(t)/N = 1 - R(t)$$

که در آن $n_f$ تعداد المان های شکست خورده است. $n_f = N - n$

# مفاهیم اولیه

- نرخ شکست: به صورت نرخ زمانی المانهای شکست خورده $dn/dt$ به تعداد المان های در حال کار تعریف می شود:

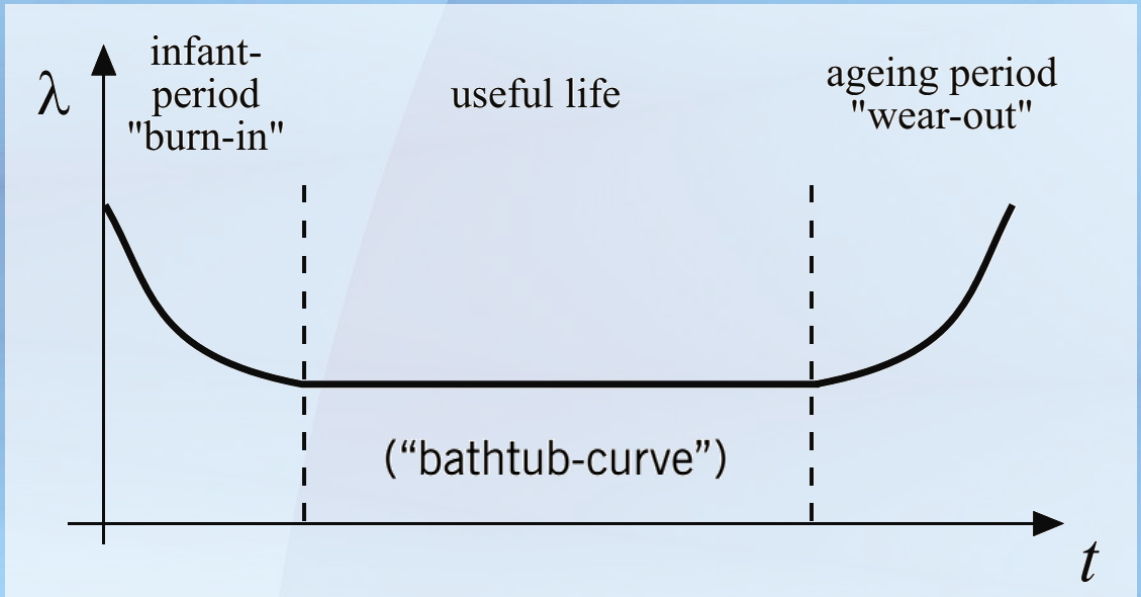
$$\lambda(t) = \frac{1}{n(t)} \frac{dn_f(t)}{dt} = \frac{1}{R(t)} \left( \frac{-dR(t)}{dt} \right) = \frac{1}{1 - Q(t)} \frac{dQ(t)}{dt}$$

به عبارت دیگر:

$$\lambda(t) = \frac{1}{\text{number of functioning elements}} \frac{\text{number of failures}}{\text{time interval}}$$

# مفاهیم اولیه

- بررسی های تجربی نشان داده تجهیزات الکترونیکی و الکترومکانیکی دارای نرخ شکست متفاوتی به زیر می باشند:
  - نرخ کاهشی طول عمر بعد از نصب (مرگ زودهنگام)(infant mortality)
  - نرخ تقریبا ثابت شده (عمر موثر) (useful life)
  - نرخ افزایشی در دوران افزایش طول عمر



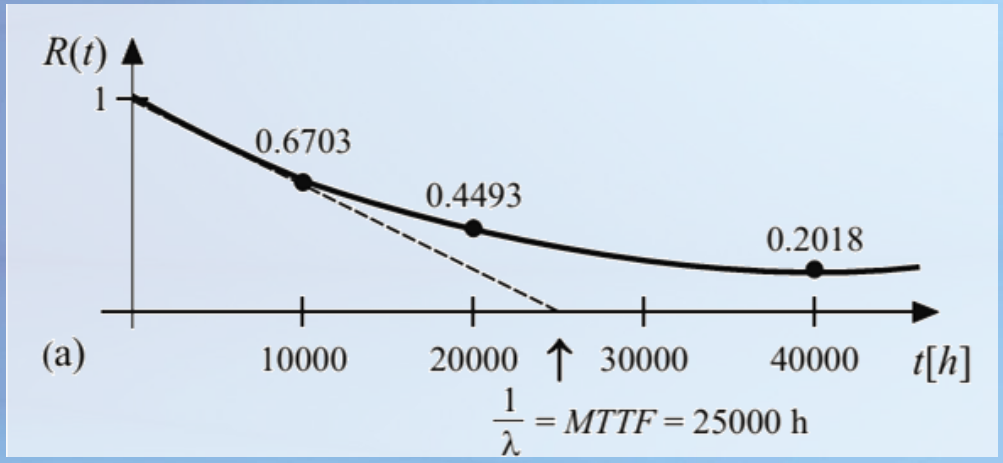
# مفاهیم اولیه

– در دوره طول عمر مفید سیستم، نرخ ثابت شکست $\lambda$ سبب رسیدن به قانون شکست نمایی خواهد شد:

$$R(t) = e^{-\lambda t}$$

– برای شرایط ابتدایی قابلیت اطمینان نرخ به صورت کاهشی بوده که به صورت زیر قابل نمایش است:

$$\lim_{t \to 0} \frac{dR(t)}{dt} = -\frac{1}{\lambda}$$



# مفاهیم اولیه

- یکی از سنجشهای تعیین قابلیت اطمینان محاسبه MTTF است که مقدار آن برابر با مقدار متوسط بدون شکست (کار کرد درست) زمان عملکرد تا رسیدن به شکست است:

$$\mathrm{MTTF} = E\{t_F\} = \lim_{V\to\infty} \frac{1}{N} \sum_{i=1}^{N} t_{fi}$$

- محاسبه MTTF به صورت تقسیم تعداد المان های فعال به تعداد نمونه های شکست خورده در واحد زمان نیز قابل محاسبه است:

$$\mathrm{MTTF} = \frac{n(t)}{\frac{dn_f(t)}{dt}} = \frac{\text{number of functioning elements}}{\frac{\text{number of failures}}{\text{time interval}}}$$

# مفاهیم اولیه

- با مقایسه نرخ شکست و MTTF می توان نتیجه گرفت:

$$\text{MTTF} = \frac{1}{\lambda}$$

- همچنین برای نرخ ثابت شکست در طول عمر سیستم بر اساس قانون شکست نمایی خواهیم داشت:

$$\text{MTTF} = \int_0^\infty R(t)dt = \int_0^\infty e^{-\lambda t}dt = \frac{1}{\lambda}$$

# مفاهیم اولیه

– نرخ شکست معمول برای برخی از تجهیزات مکانیکی و الکترونیکی به شرح زیر است:

| Mechanical elements | $\lambda[h^{-1}]$ | Electromechanical elements | $\lambda[h^{-1}]$ |
|---|---|---|---|
| ball bearing | $1.64 \cdot 10^{-6}$ | actuator, general | $26 \cdot 10^{-6}$ |
| sleeve bearing | $2.38 \cdot 10^{-6}$ | brush, general | $9 \cdot 10^{-6}$ |
| belt | $19.72 \cdot 10^{-6}$ | cable, general | $1 \cdot 10^{-6}$ |
| coupling | $5.54 \cdot 10^{-6}$ | electric motor, general | $9 \cdot 10^{-6}$ |
| gear | $4.69 \cdot 10^{-6}$ | generator, general | $73 \cdot 10^{-6}$ |
| pump | $43.65 \cdot 10^{-6}$ | regulator, general | $13 \cdot 10^{-6}$ |
| seal | $5.47 \cdot 10^{-6}$ | | |
| valve, hydraulic | $8.83 \cdot 10^{-6}$ | | |

1974
University of Guilan

# مفاهیم اولیه

- چگالی شکست (Failure density): یک معیار برای تعیین عدم قابلیت اطمینان یک سیستم است

$$q(t) = \frac{dQ(t)}{dt} = \frac{1}{N}\frac{dn_f(t)}{dt} = -\frac{dR(t)}{dt}$$

- برای $\lambda$ ثابت خواهیم داشت:

$$q(t) = \lambda e^{-\lambda t}$$

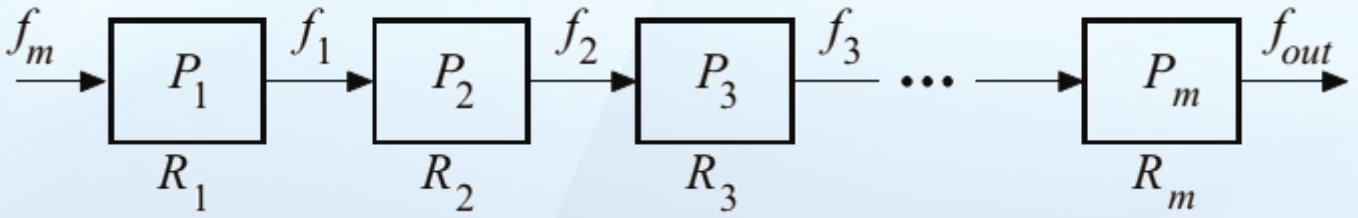
- بنابراین احتمال واحدهای شکست خورده در یک بازه زمانی $\Delta t$ به شکل زیر بدست خواهد آمد

$$\Delta n_f \approx N\lambda e^{-\lambda t}\Delta t$$

# مفاهیم اولیه

- قابلیت اطمینان در المان های متصل به هم

**الف) المان های سری**




$$R_{tot}(t) = \prod_{i=1}^{m} R_i(t) = e^{-\sum_{i=1}^{m} \lambda_i t} = e^{-\lambda_{tot} t}$$

که به آن قانون ضرب قابلیت اطمینان گویند

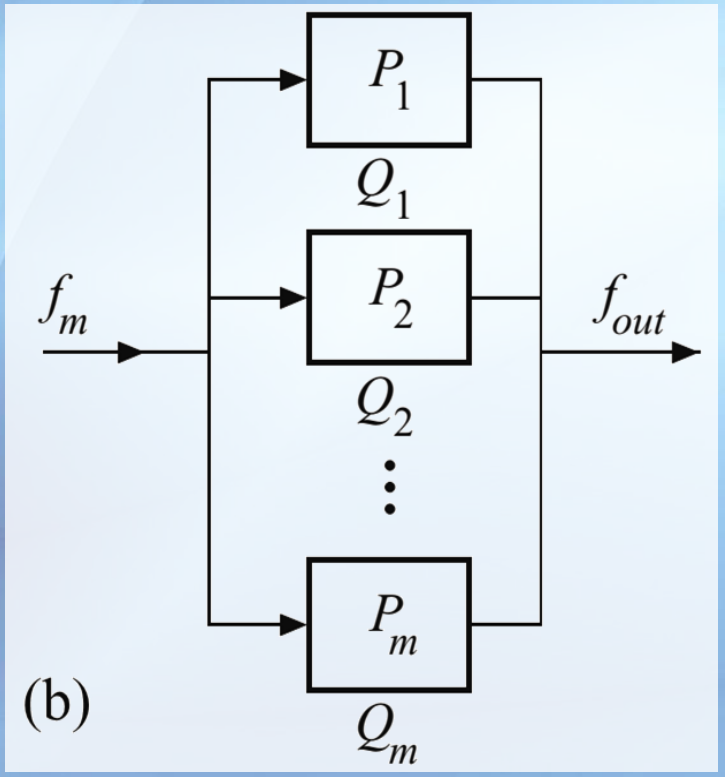
# مفاهیم اولیه

- در این صورت نرخ شکست کلی و MTTF کلی به صورت زیر بدست خواهد آمد:

$$\lambda_{tot} = \sum_{i=1}^{m} \lambda_i$$

$$\mathrm{MTTF}_{tot} = \left[ \sum_{i=1}^{m} (\mathrm{MTTF}_i)^{-1} \right]^{-1}$$

# مفاهیم اولیه




**ب) المان های موازی**

– اگر المان ها به صورت موازی نصب شوند، سیستم دارای افزونگی بوده و عدم اطمینان هر یک به صورت زیر محاسبه می شود

$$Q_i(t) = 1 - R_i(t)$$

بنابراین، بر اساس قانون ضرب عدم اطمینان داریم:

$$Q_{tot}(t) = \prod_{i=1}^{m} Q_i(t) = \prod_{i=1}^{m} (1 - R_i(t))$$

# مفاهیم اولیه

- بنابراین قابلیت اطمینان المان های موازی به صورت زیر بدست خواهد آمد:

$$R_{tot}(t) = 1 - \prod_{i=1}^{m} (1 - R_i(t)) = 1 - \prod_{i=1}^{m} \left(1 - e^{-\lambda_i t}\right)$$

- همچنین مقدار MTTF برای المان های موازی خواهد بود:

$$\text{MTTF} = \int_0^{\infty} R(t)dt = \int_0^{\infty} \left[1 - \left(1 - e^{-\lambda t}\right)^m\right] dt$$

# مفاهیم اولیه

- عوامل تاثیر گذار بر قابلیت اطمینان تجهیزات مختلف (مثال)
  - سیستم های مکانیکی: تاب برداشتن، خستگی، شکست، ساییدگی، خوردگی
  - سیستم های الکتریکی: فرآیند تولید، شرایط محیطی، بار داخلی

# مفاهیم اولیه

- افزایش قابلیت اطمینان سیستم های مختلف و درجه عوامل تاثیرگذار بر آن در جدول زیر ارائه شده است.

| improvement of reliability | components | | | | |
|---|---|---|---|---|---|
| | mechanical | hydraulic | electrical | electronic hardware | software |
| oversizing | ++ | + | + | + | 0 |
| maintenance | ++ | ++ | + | 0 | + |
| protection | ++ | ++ | + | ++ | 0 |
| wear reduction | ++ | + | + | 0 | 0 |
| redundancy | 0 | + | + | ++ | + |
| • static | 0 | + | + | ++ | 0 |
| • dynamic | 0 | 0 | + | ++ | + |
| • diversity | 0 | 0 | 0 | ++ | ++ |

1974
University of Guilan

# مفاهیم اولیه

- در دسترس بودن (Availability) : احتمال عملکرد مطلوب و موثر یک سیستم یا تجهیر در یک بازه زمانی مشخص است.

  – در دسترس بودن مهمترین فاکتور برای کاربر یک سیستم است.

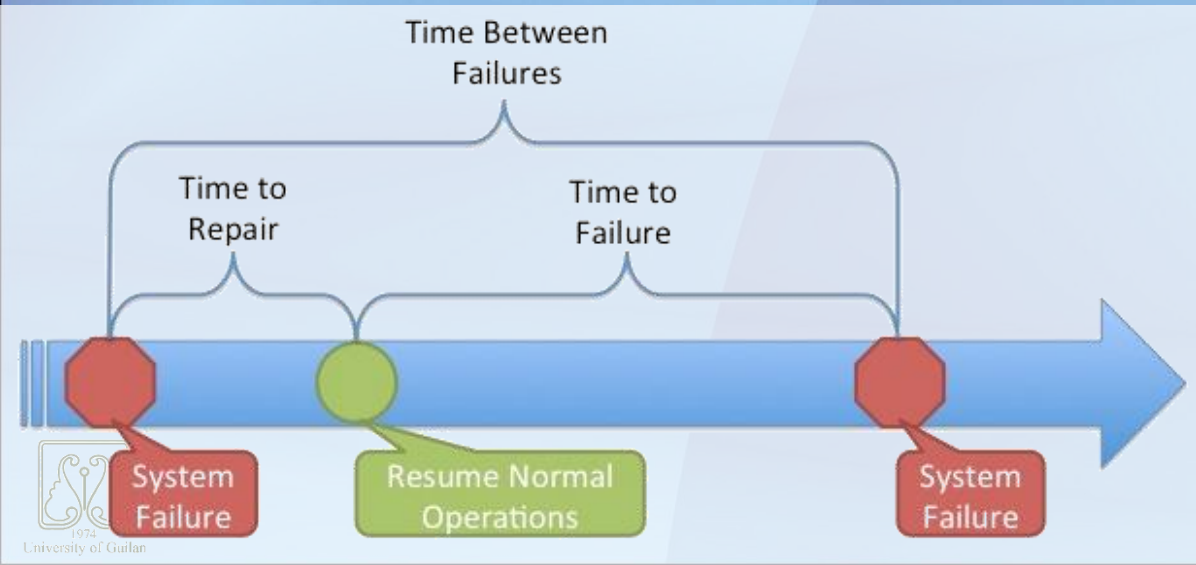
  – در دسترس بودن بر اساس مقدار زمان مورد نیاز برای تعمیرات و برگرداندن سیستم به شرایط کاری پس از شکست و بعد عمل کردن سیستم است.

# مفاهیم اولیه

- یک معیار اندازه گیری در دسترس بودن

$$A = \frac{MTTF}{MTTF+MTTR}$$

بوده که در آن MTTR و MTTF به ترتیب زمان متوسط برای تعمیر و شکست سیستم است.




$$MTBF = MTTF + MTTR$$

If $MTTR \ll MTTF$, then

$$MTBF \approx MTTF$$

# مفاهیم اولیه

- برای حداکثر شدن زمان در دسترس بودن می بایست مقدار MTTF نسبت به MTTR بزرگ باشد
- برای بزرگ بودن زمان MTTF نیازمند:
  - اجزا با قابلیت اطمینان بالا هستیم
  - تحمل پذیری در برابر عیب با استفاده از ساختار افزونه هستیم

- برای کوچک بودن زمان MTTR نیازمند:
  - عیب یابی سریع و قابل اطمینان هستیم
  - حذف سریع و قابل اطمینان عیب در زمان کوتاه هستیم

# مفاهیم اولیه

- ایمنی (Safety): توانایی یک سیستم در عدم به مخاطره انداختن افراد، تجهیزات و یا محیط زیست



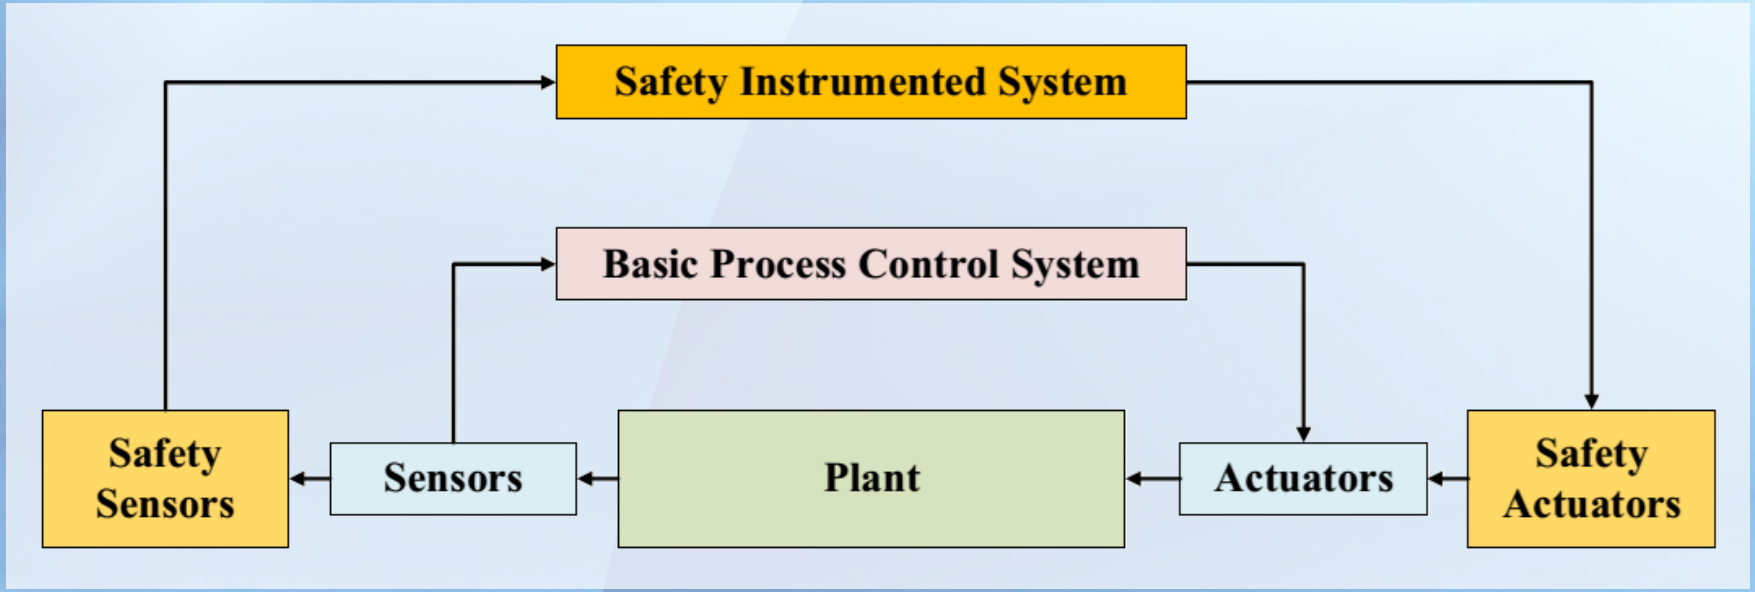

  - به صورت خلاصه: عدم ایجاد خطر
  - ایمنی به مخاطرات حاصل از عیب، شکست و یا بدکارکردن سیستم مربوط می شود.
  - ایمنی معمولا به صورت یک اعلان یا Status دیده می شود که در آن ریسک از یک حد بازه مشخص فراتر نرود.

# مفاهیم اولیه

- ایمنی و قابلیت اطمینان معمولا با ترکیبی از:
  - اجتناب از عیب
  - حذف عیب
  - تحمل پذیری عیب
  - عیب یابی و تشخیص عیب
  - حفاظت و پایش پیشرفته

# مفاهیم اولیه

- به سیستم های ایمنی که با استفاده از تجهیزات ابزار دقیق موجود در یک فرآیند و به صورت فعال وظیفه حفاظت سیستم را به عهد دارند اصلاحا SIS گفته می شود

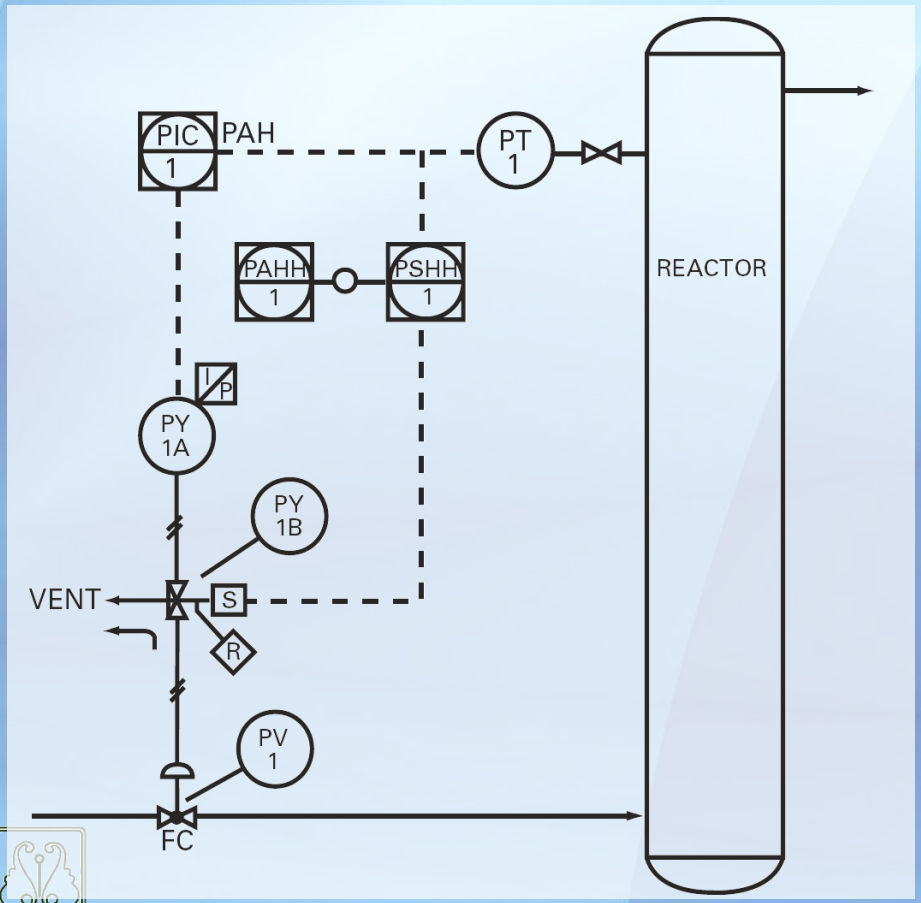


# مفاهیم اولیه

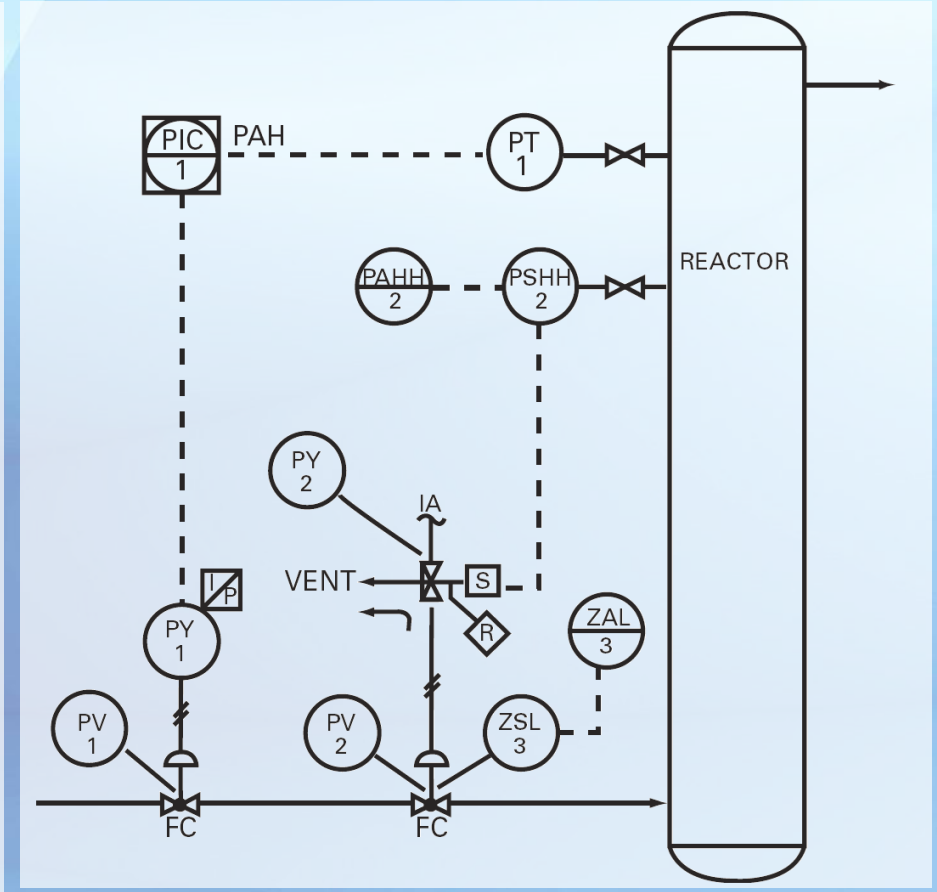
- سایر اسامی سیستم ایمنی:
- Discrete Systems
- Emergency Shutdown Systems (ESD) or (ESS)
- Interlocks
- Interlock Systems
- Protective Logic Systems
- Safety Instrumented Systems (SIS)
- Safety Interlock Systems
- Safety Shutdown Systems (SSD)
- Safety Systems
- Shutdown Systems

# مفاهیم اولیه

- Integrated SIS



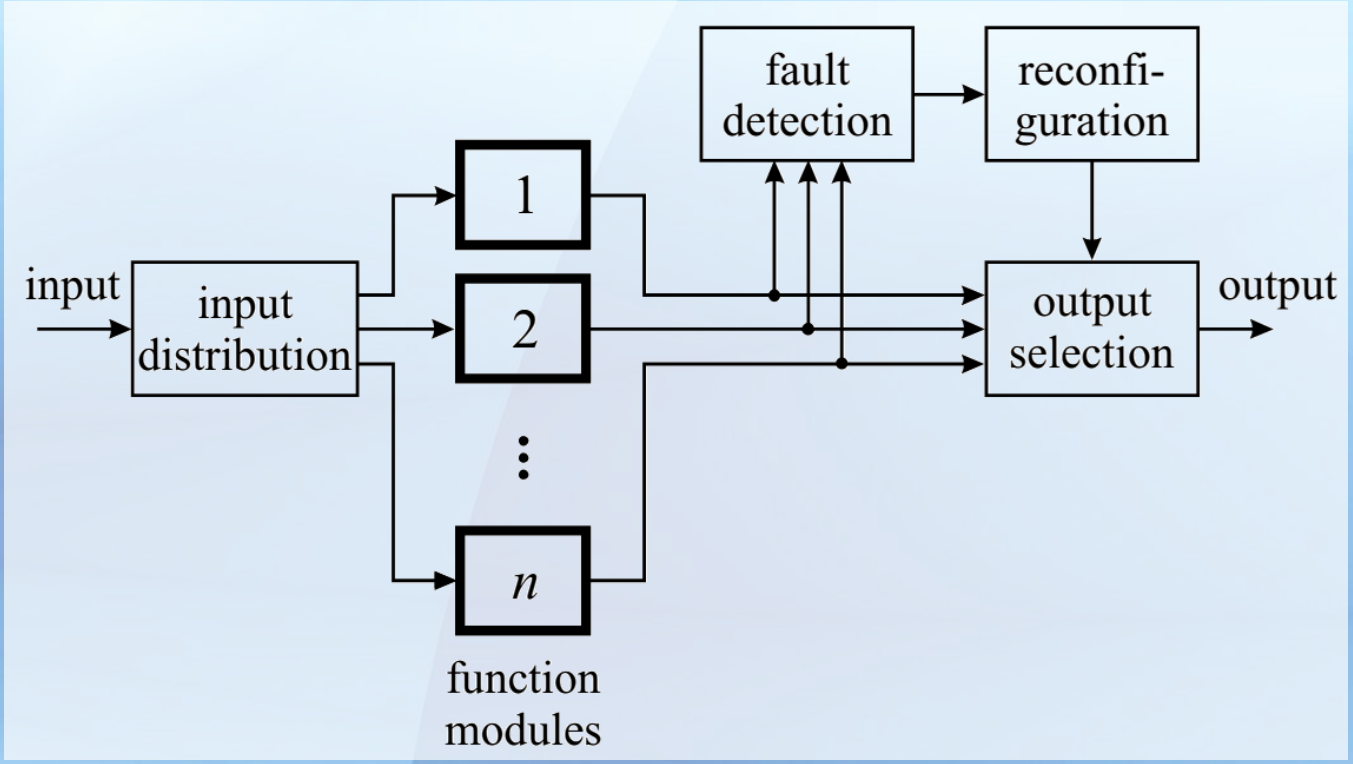

- Separated SIS




1974
University of Guilan

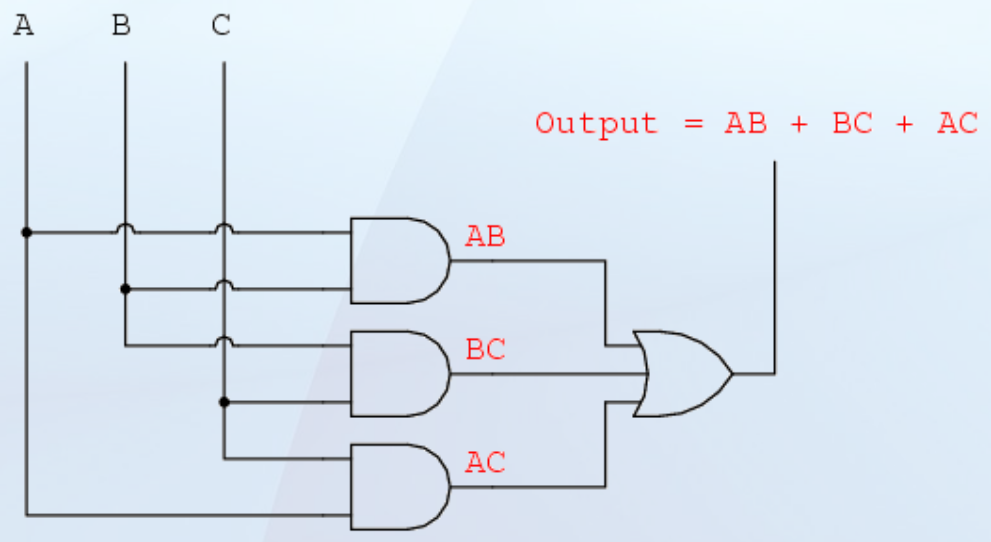
# مفاهیم اولیه

- حفاظت و افزونگی یکی از بهترین روش های افزایش قابلیت اطمینان هستند



# مفاهیم اولیه

- مکانیزم افزونگی در سیستم های اندازه گیری
- Voting 2-out-of-3

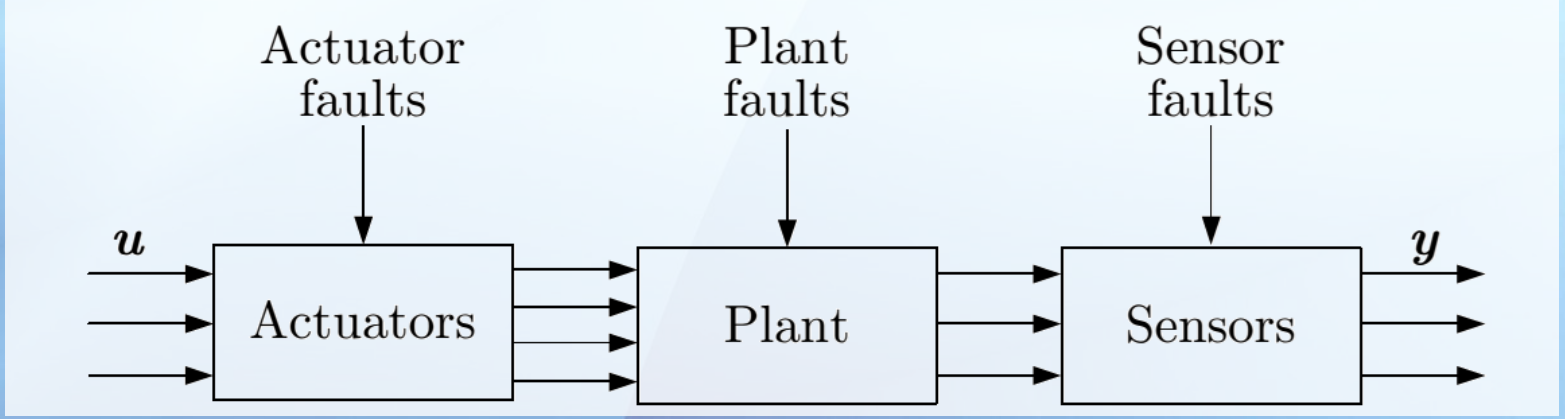



برای نیروگاه های اتمی:

– Voting 3-out-of-5

# مفاهیم اولیه

- انواع عیب (Fault):




همانطور که در شکل فوق مشاهده می شود عیب به سه شکل می تواند ظاهر شود:

# مفاهیم اولیه

- عیب سیستم (Plant fault): عیب هایی که باعث ایجاد خصوصیات دینامیکی I/O یک سیستم شوند.

| type of faults | | components | | | |
|---|---|---|---|---|---|
| | | mechanical components | electrical components | electronic hardware | software |
| form | systematic | √ | | √ | √ |
| | random | | √ | √ | |
| time behavior | permanent | | | √ | √ |
| | transient | √ | √ | √ | |
| | intermittent | | √ | √ | √ |
| | noise | | √ | √ | |
| | drift | √ | √ | √ | |
| extent | local | √ | √ | √ | √ |
| | global | | | √ | √ |

# مفاهیم اولیه

- عیب سنسور (Sensor fault): عیب هایی که خصوصیات دینامیکی سیستم را تحت تاثیر قرار نداده ولی مقدار اندازه گیری خوانده شده توسط سنسور دارای خطا (error) است.

$$x(t) = x^*(t) + w(t)$$

$x^*(t)$: the true value of measured variable

$w(t)$: measurement noise

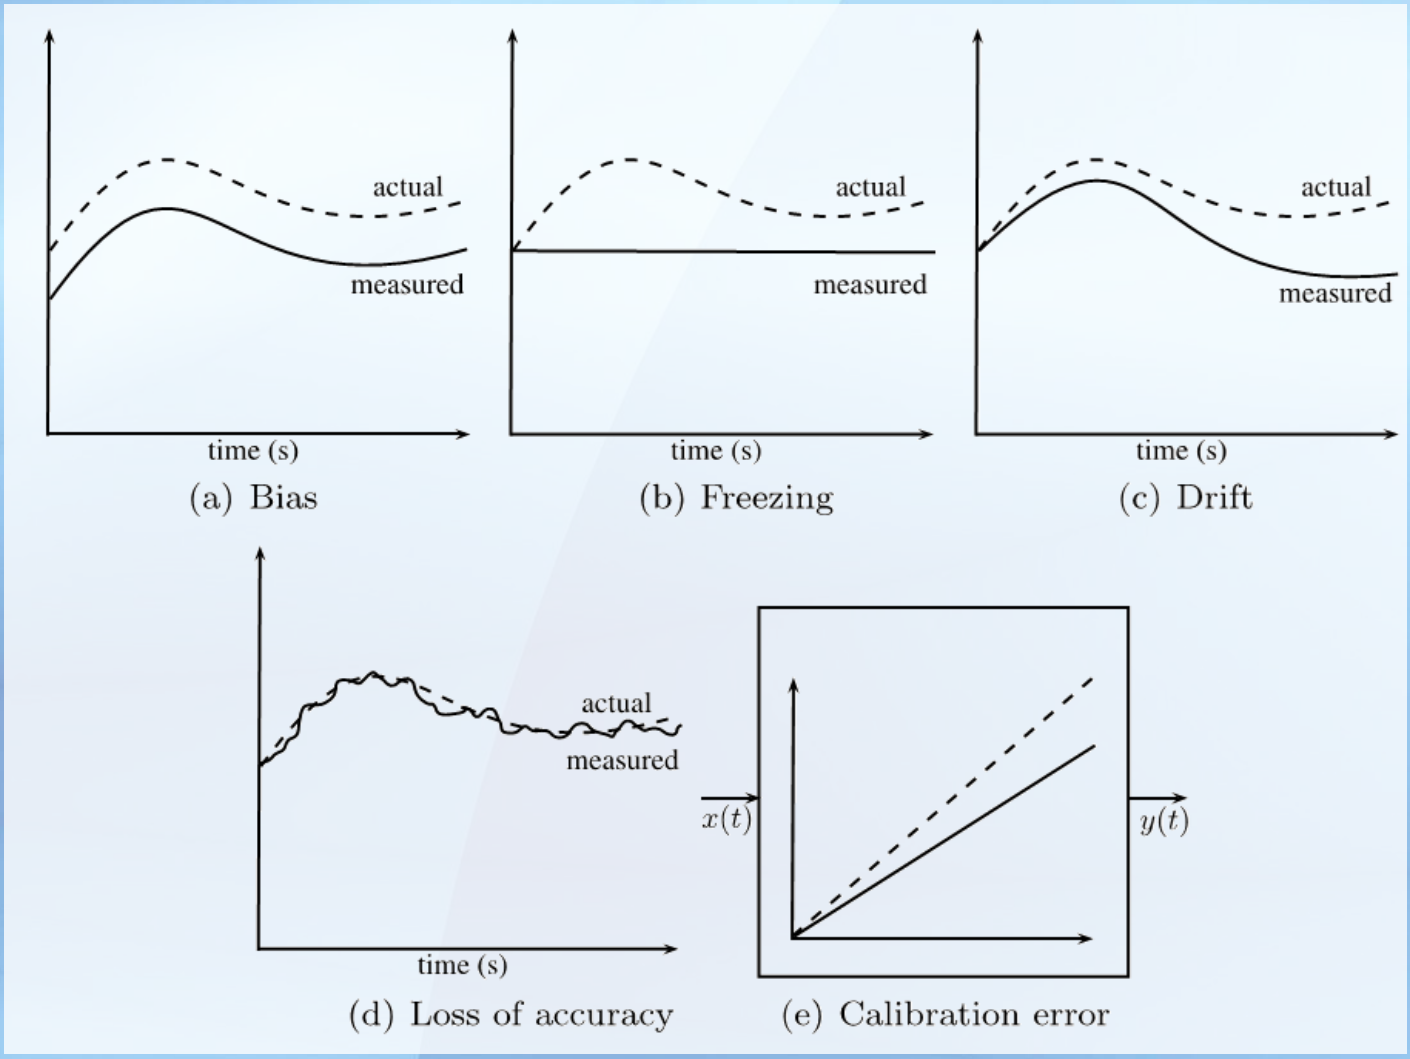
– در حالت عمومی برای عیب در سنسور وجود دارد:

- عیب کوتاه یا موقت (Short fault)
- عیب ثابت (Constant faults)
- عیب نویز (Noise fault)

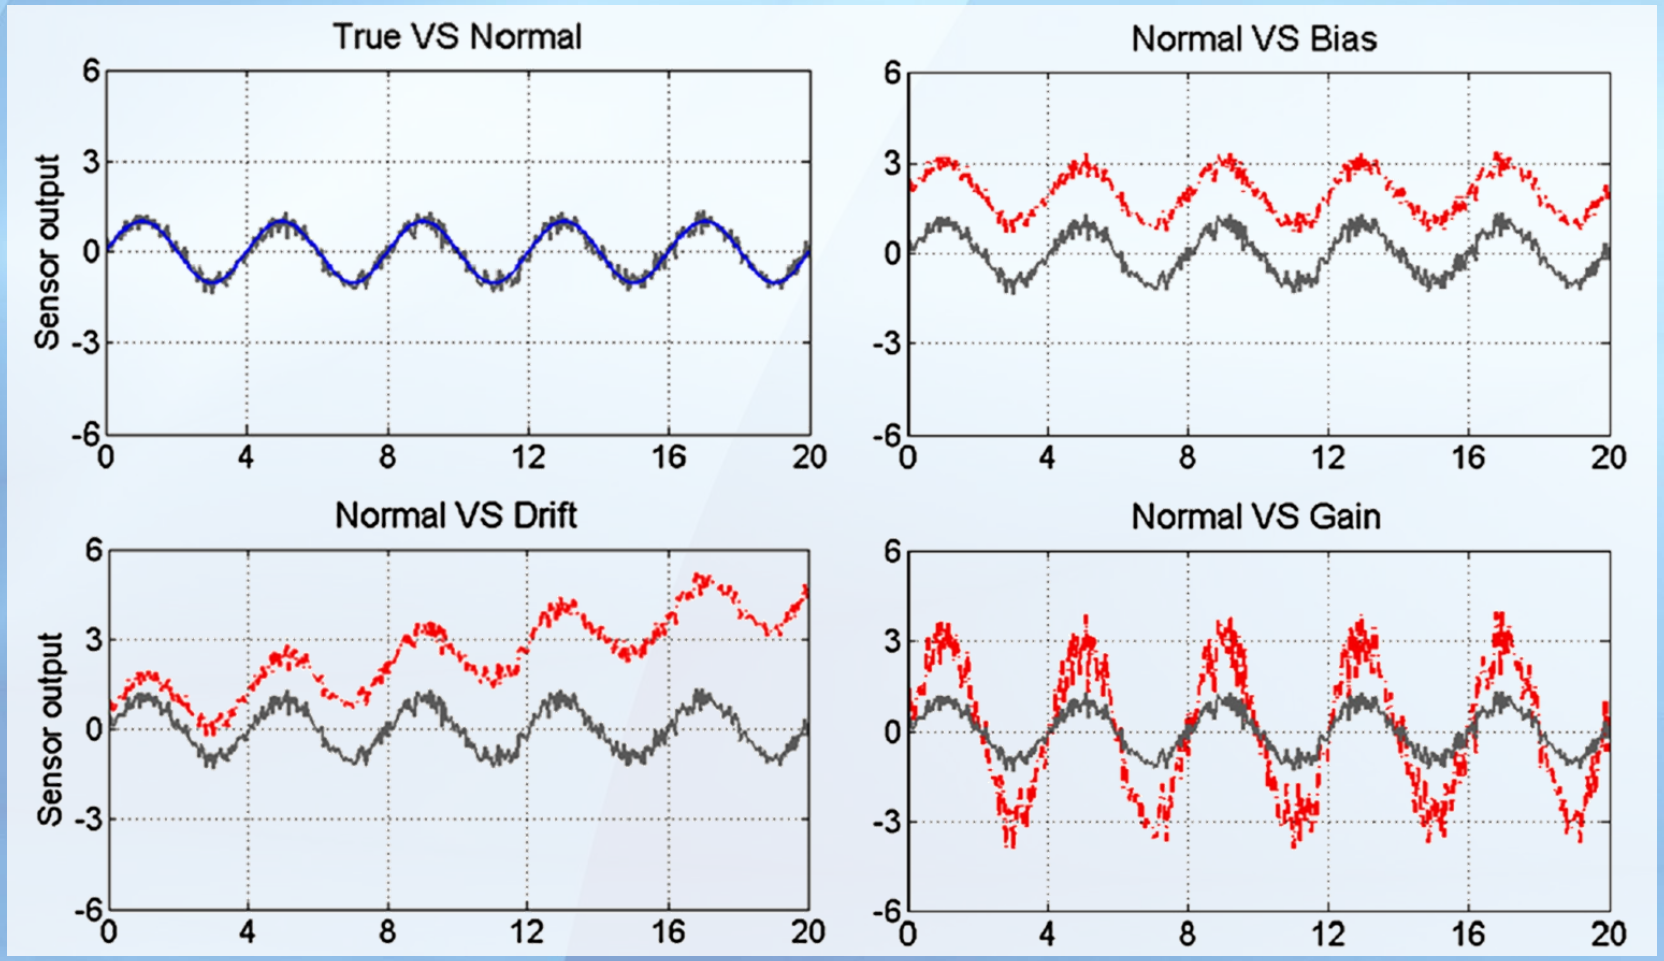
# مفاهیم اولیه

- انواع عیب و خرابی در سنسورها
  - عیب انحراف (Bias)
  - عیب راندگی (Drift fault)
  - عیب بهره (Gain fault)
  - افت دقت (Precision degradation)
  - خرابی کامل ۱ از نوع اختلاف ثابت (Constant)
  - خرابی کامل ۲ از نوع اختلاف ثابت بهمراه نویز
  - خرابی کامل ۳ از نوع نویز زیر (Bottom noise) یا (Freezing)

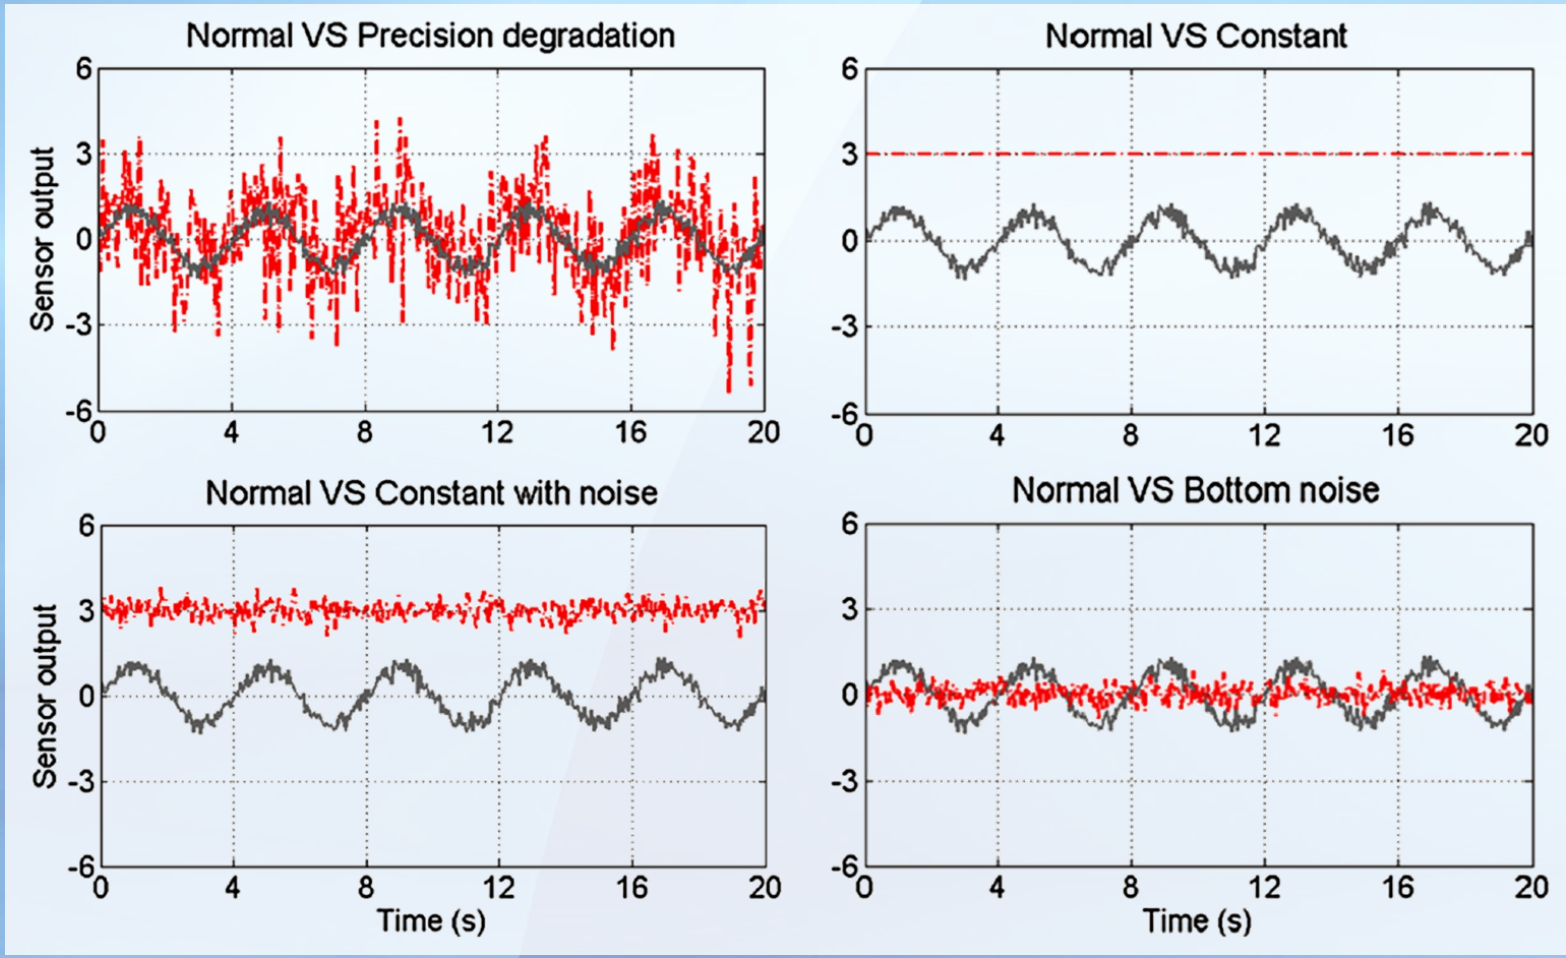
# مفاهیم اولیه



# مفاهیم اولیه



# مفاهیم اولیه



# مفاهیم اولیه

- عیب عملگر (Actuator fault): که بصورت عملکرد نامطلوب یا بد کار کردن (Malfunction) در تجهیزات عملگری سیستم ظاهر می شود.
  - عیب گیرکردگی (Lock-in-place)

$$u_{i,k} = u_{i,t_f} = \text{const}, \quad \forall k > t_f.$$

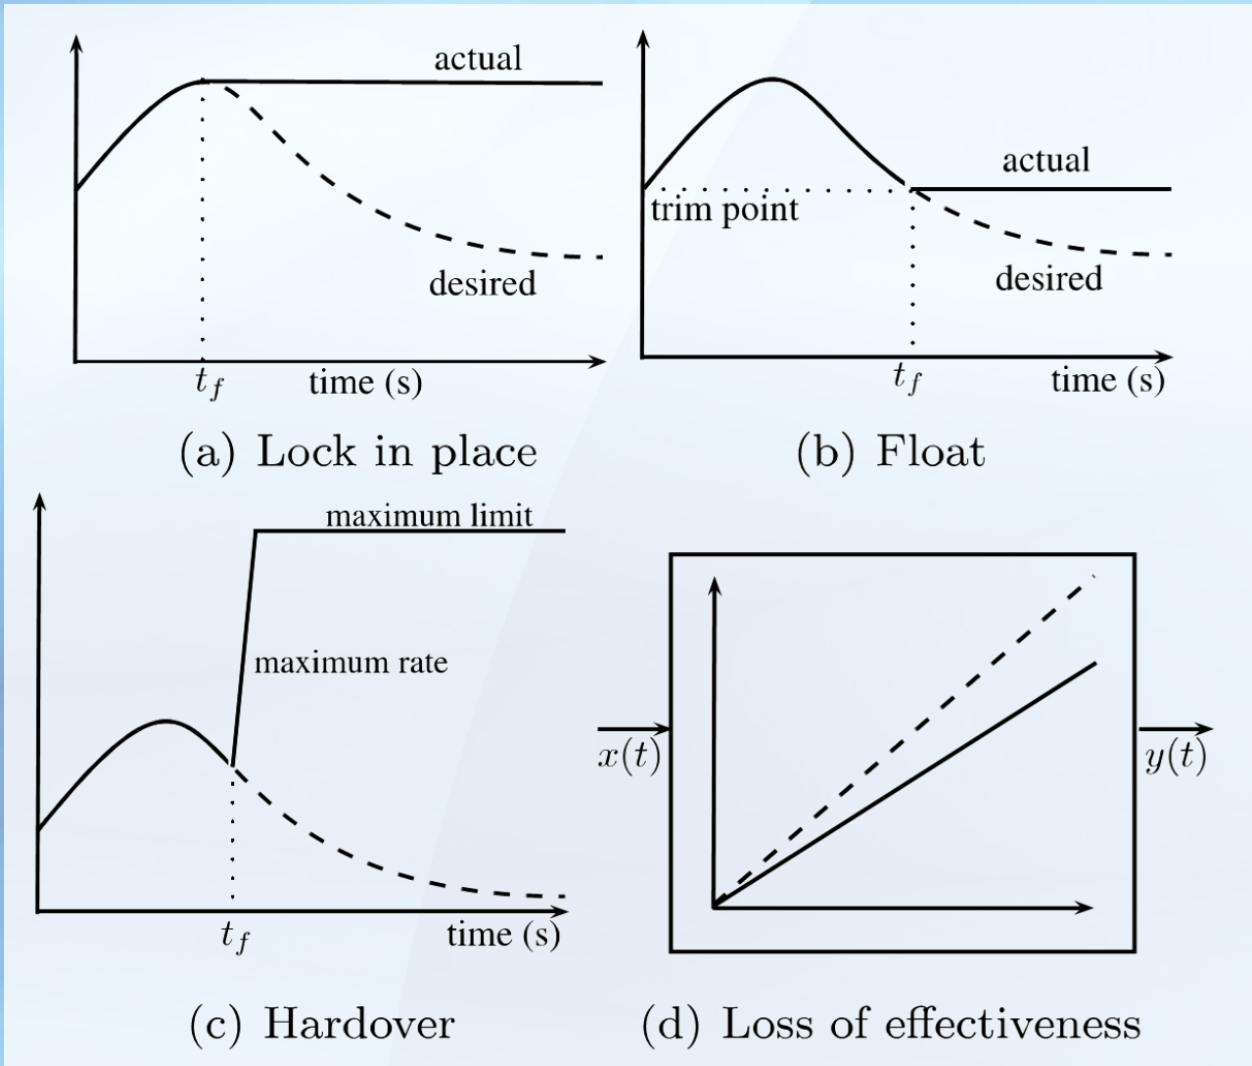
  - خروج (Outage)

$$u_{i,k} = 0, \quad \forall k > t_f$$

  - افت کارایی (Loss of effectiveness)

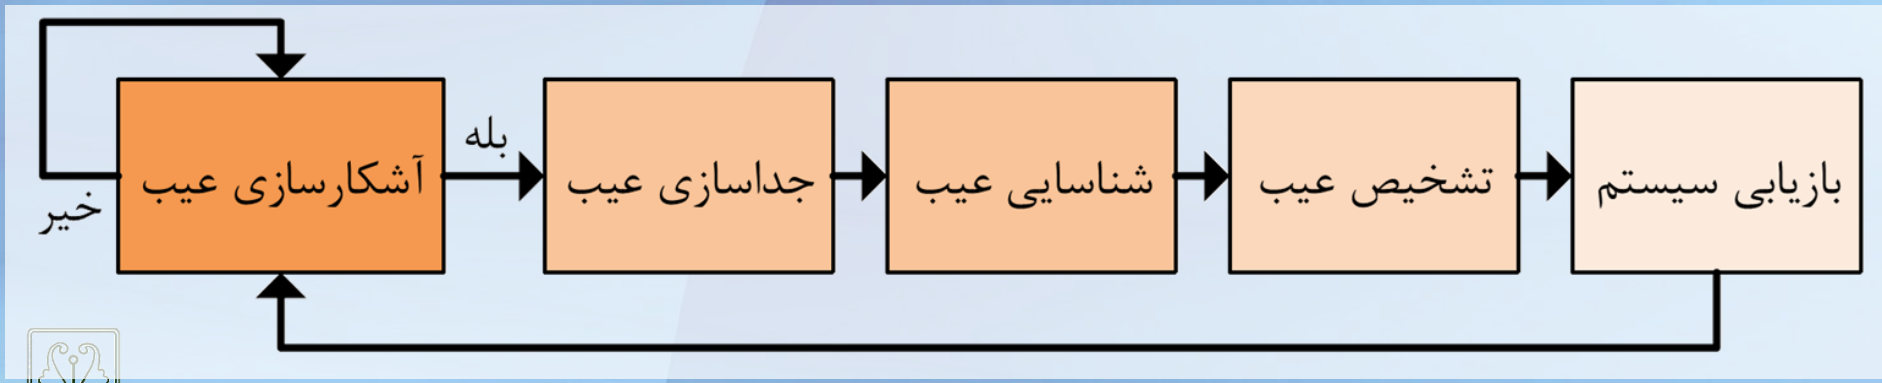
$$u_{i,k} = k_i u^c_{i,k}, \quad 0 < k_i < 1 \quad \forall k > t_f$$

# مفاهیم اولیه



# مفاهیم اولیه

- روند پایش وضعیت یک سیستم شامل ۵ فرآیند اصلی است:
  - ۱- آشکارسازی عیب یا عیب‌یابی (Fault Detection)
  - ۲- جداسازی عیب (Fault Isolation)
  - ۳- شناسایی عیب (Fault Identification)
  - ۴- تشخیص عیب (Fault Diagnosis)
  - ۵- بازیابی سیستم (System Recovery)



# مفاهیم اولیه

- عیب‌یابی(Fault Detection): تعیین وجود عیب در سیستم در زمان وقوع آن.

- جداسازی عیب (Fault Isolation): تعیین نوع، محل و زمان یافتن عیب که در ادامه عیب‌یابی انجام می‌شود.

- شناسایی عیب (Fault Identification): تعیین اندازه و رفتار وابسته به زمان مرتبط با عیب (متغیرهایی که تحت تاثیر عیب قرار می گیرند) که در ادامه جداسازی عیب انجام می‌شود

# مفاهیم اولیه

- تشخیص عیب (Fault Diagnosis): تعیین نوع، اندازه، محل و زمان وقوع عیب. این عملیات در ادامه عیب‌یابی انجام شده و شامل عیب‌یابی، جداسازی و شناسایی عیب می‌شود.

- بازیابی سیستم (System Recovery): در این مرحله اثر عیب برطرف شده و روند پایش سیستم مجددا تکرار می شد. به این فرآیند مداخله یا intervention نیز گویند.

- تمامی این ۵ مرحله ممکن است در پایش یک سیستم اجرا شوند.

# مفاهیم اولیه

- الزامی به انجام هر یک از مراحل نیست.
  - ممکن است تشخیص عیب انجام شود بدون اینکه الزاما متغیرهایی که تحت تاثیر آن قرار گرفته اند، شناسایی شوند.
- الزامی برای انجام خودکار یا اتوماتیک این مراحل وجود ندارد.
  - عیب یابی فقط برای آگاهی اپراتور از وضعیت سیستم باشد
  - فرآیند بازآرایی سیستم ممکن است توسط عملکرد دستی اپراتور جبران شود

- در اغلب موارد، هدف کاملاً خودکار بودن فرآیند پایش نبوده، بلکه برقراری ارتباط کیفی بین اپراتورهای واحد و مهندسان با حلقه پایش سیستم است

# مفاهیم اولیه

- هنگامی که عیب به درستی تشخیص داده شود، روش بهینه برای مقابله با آن ممکن است بسادگی قابل تشخیص نباشد.

- اغلب می‌توان عملکرد سیستم های معیوب تحت کنترل را از طریق بازآرایی فرآیند، ترمیم فرآیند و یا بازتنظیم (retuning) کنترل کننده ها احیا نمود.

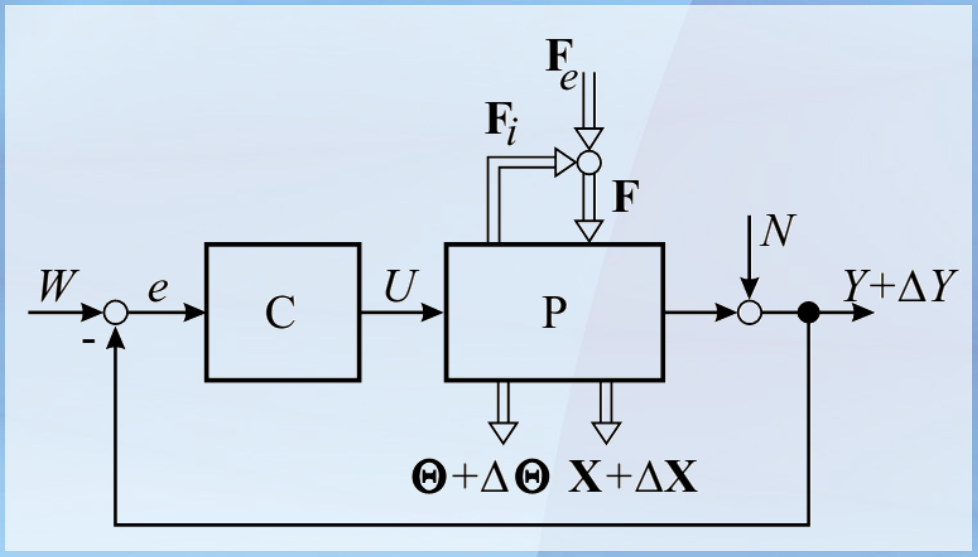
- لازمه این عمل تعیین کنترل کننده ای است که تنظیم آن بتواند نیاز فرآیند را برای رسیدن به شرایط مطلوب تامین کند.

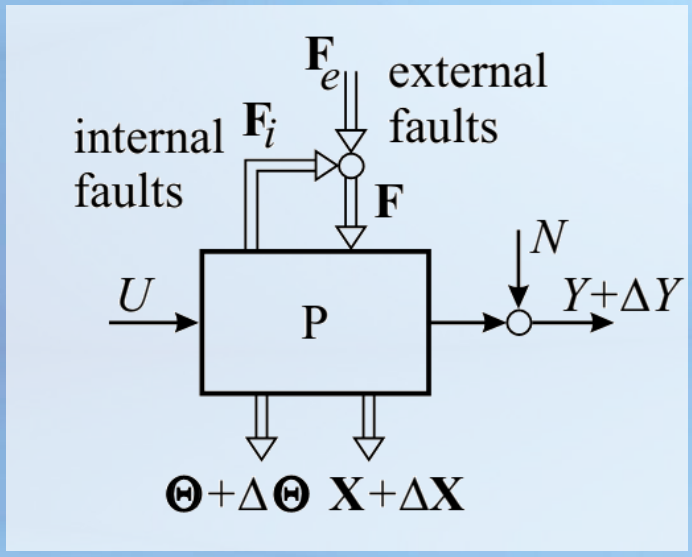
فصل سوم

# روش‌های عیب‌یابی و تشخیص عیب

# نظارت ابتدایی

- یک سیستم حلقه باز و یا حلقه بسته می تواند تحت تاثیر عیب داخلی و یا خارجی قرار گیرد.
- مساله مهم شناسایی تاثیری است که این عیب ها بر روی خروجی و یا متغیرهای داخلی سیستم می گذارند.



# نظارت ابتدایی

- اغتشاش (Disturbance): ورودی نامعلوم و کنترل نشده به سیستم که می تواند سبب ایجاد تغییرات در خروجی یا متغیرهای سیستم شده.
  - در نظر نگرفتن این عامل می تواند سبب ایجاد اخطار کاذب یا False Alarm شود.

- اختلاف (Residual): نشانگر خطا، بر اساس اختلاف بین مقادیر اندازه‌گیری شده و مقدار واقعی یک کمیت یا محاسبات مبتنی بر معادلات مدل است.

# روش های عیب یابی و تشخیص عیب

- روش های عیب یابی و تشخیص عیب در یک سیستم در حالت کلی به دو شکل کلی قابل شناسایی هستند:

۱- روش های دانش پایه (Knowledge-based Methods)

۲- روش های تحلیلی (Analytical Methods)

# روش دانش پایه

- بررسی متغیرهای اندازه گیری شده توسط اپراتور خبره و تحلیل شرایط موجود ایده اصلی روش های عیب یابی دانش پایه می باشد.
- به دانش فرد خبره اصلاحا دانش اکتشافی یا heuristic knowledge گویند.
- برای این منظور نیازمند وجود نشانه های تحلیلی از سیستم هستیم.
- نشانه (Symptom) : تغییر یک کمیت قابل اندازه‌گیری نسبت به عملکرد عادی آن

# روش تحلیلی

- روش های تحلیلی، بر اساس تهیه اطلاعات تحلیلی قابل ارزشیابی از یک سیستم عمل می کنند.

- روش تحلیلی در حالت کلی، به سه شکل قابل شناسایی است:

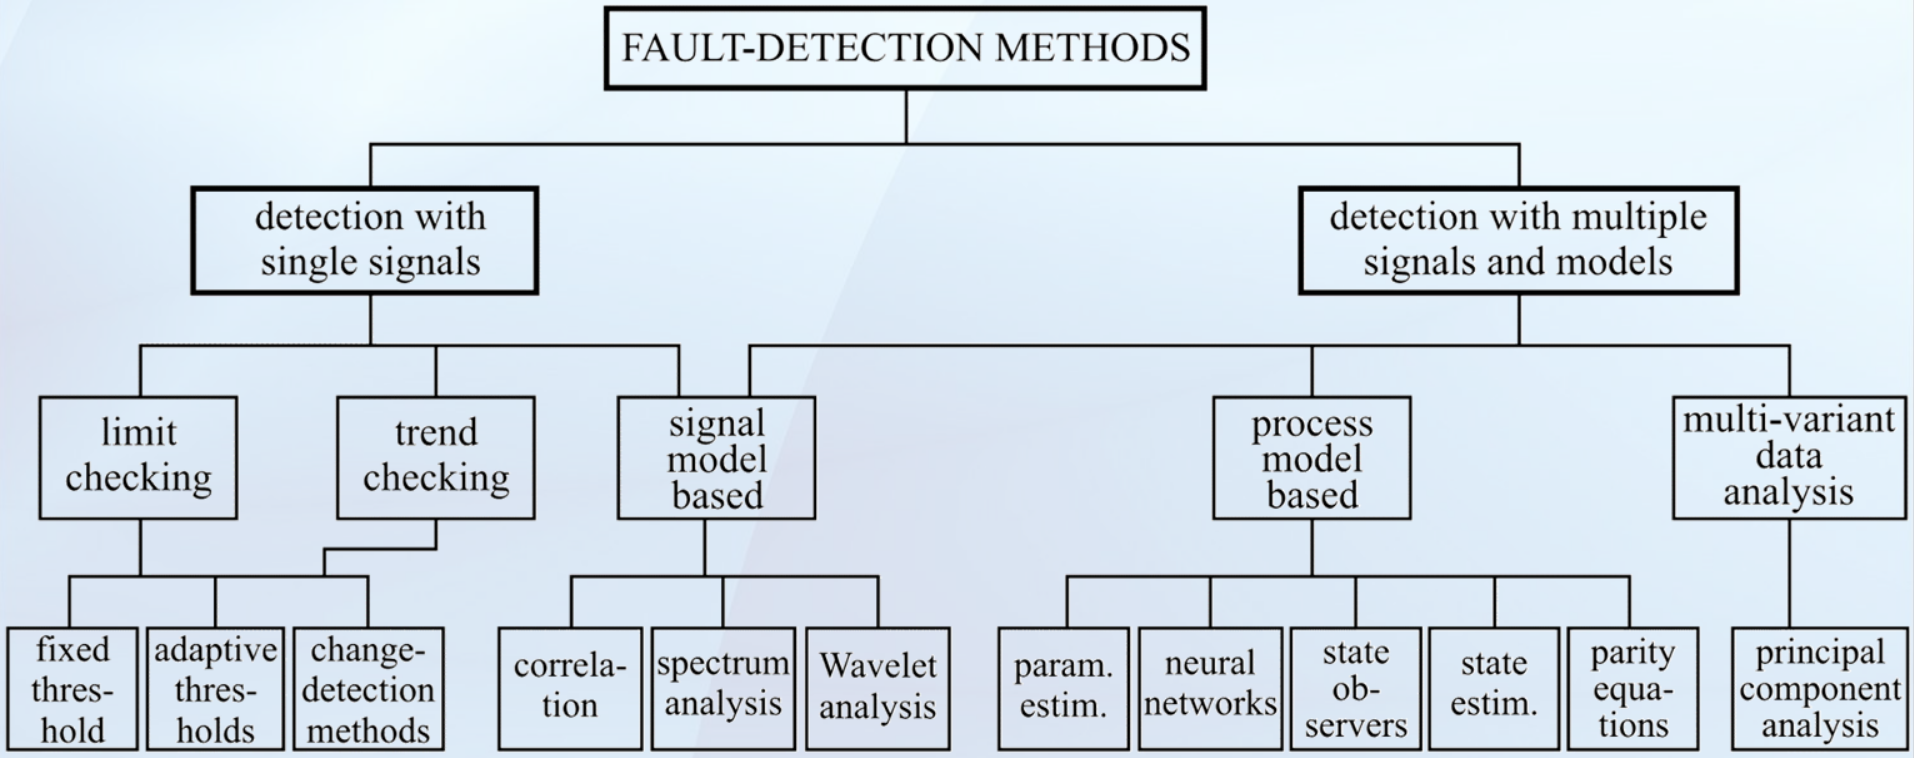
۱- روش های سیگنال-پایه (Signal-based)

۲- روش های مدل-پایه (Model-based)

۳- روش های سیگنال-مدل-پایه(Signal-model-based)

# روش تحلیلی عیب یابی

- دسته بندی روش های تحلیلی عیب یابی

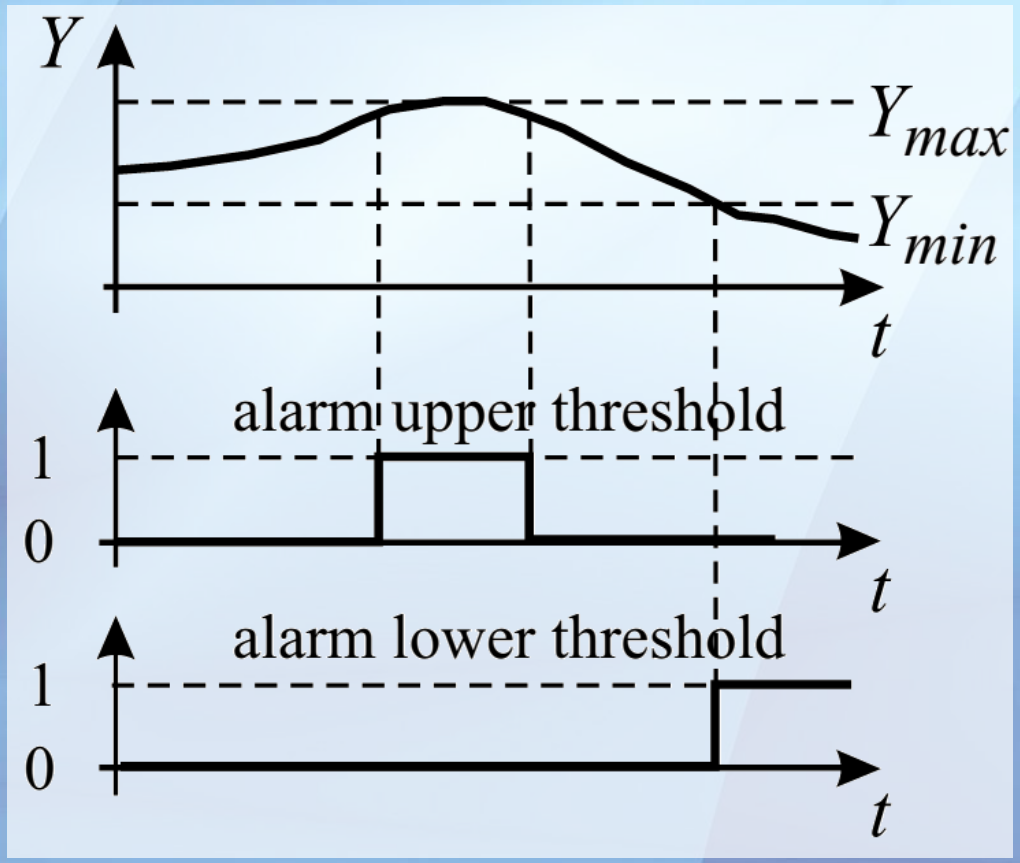


# بررسی بازه مقادیر قدرمطلق

- Limit checking of absolute values
  - معمولا برای بررسی وضعیت یک سیستم، قرار گرفتن متغیرهای آن در یک بازه به عنوان وضعیت مطلوب یا عادی سیستم در نظر گرفته می شود.
    - فشار بخار، دمای خروجی اگزوز،....
  - دو عدد حد بالا و حد پایین به عنوان آستانه یا Threshold یافتن عیب در نظر گرفته می شود.

$$Y_{min} < Y(t) < Y_{max}$$

# بررسی بازه مقادیر قدرمطلق




- انتخاب بازه مناسب برای ترشلدها نیاز به تجربه فراوان داد
  - انتخاب بازه به صورتی که تغییرات عادی سیستم به دلیل وجود اغتشاش در سیستم باعث اعلام اخطار کاذب یا False Alarm نشود
  - توانایی اعلام زودهنگام به دلیل انحراف حاصل از خطا را داشته باشد.

# بررسی روند تغییرات

- Trend checking

– کاربرد: سیستم های صنعتی، همانند توربین های بخار، توربین گاز و .... که تنش های حرارتی و یا مکانیکی می تواند آسیب جدی به سیستم وارد کند.

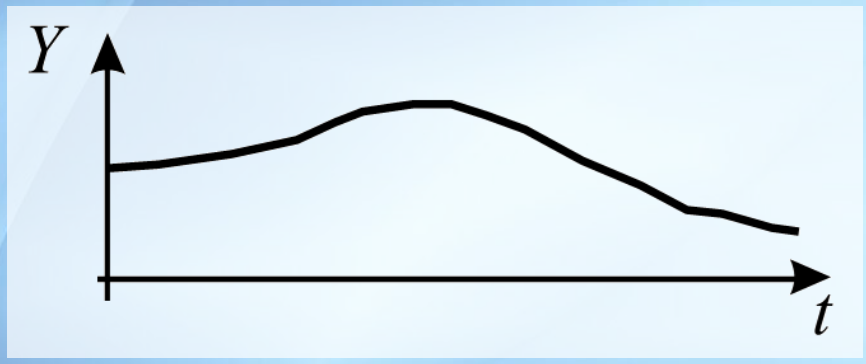
  - دمای پره توربین، ارتعاشات روتور، فشار روغن یاتاقان ها و....

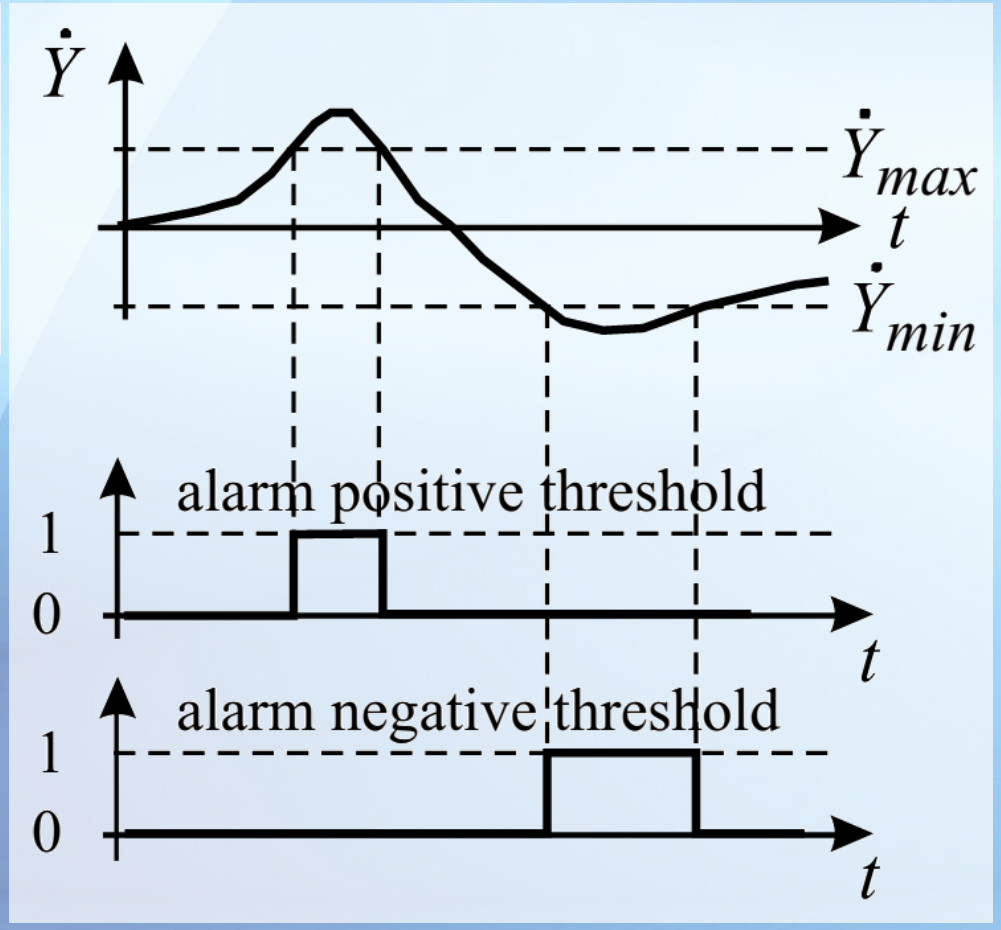
– مشتق گیری از متغییر:

$$\dot{Y} = dY(t)/dt$$

$$\dot{Y}_{min} < \dot{Y}(t) < \dot{Y}_{max}$$

# بررسی روند تغییرات




- در صورت کوچک بودن بازه ترشلد، استفاده از روند سریعتر از ترشلد خود متغیر وجود عیب را آشکار کند.

# یادآوری

- امید ریاضی یا Expected Value برای یک تابع پیوسته با تابع چگالی احتمال pdf برابر با $f(x)$ به صورت زیر تعریف می شود:

$$E[g(X)] = \int_{-\infty}^{\infty} g(x) f(x)\, dx$$

- مقدار متوسط:

$$E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx$$

# یادآوری

- واریانس

$$\mathrm{Var}(X) = E\left[(X - E[X])^2\right]$$

$$\mathrm{Var}(X) = E[X^2] - (E[X])^2$$

- کوواریانس

$$\mathrm{Cov}(X, Y) = E[(X - E[X])(Y - E[Y])]$$

$$\mathrm{Cov}(X, Y) = E[XY] - E[X]E[Y]$$

- ضریب همبستگی

$$\rho = \frac{E[(X - \mu_x)(Y - \mu_y)]}{\sigma_x \sigma_y}$$

- خودهمبستگی

$$\begin{aligned} R_{xx}(t, t+\tau) &= R_{xx}(\tau) \\ &= E[X(t)\, X(t+\tau)] \end{aligned}$$

# آشکارسازی تغییرات با آستانه باینری

- Change detection with binary thresholds
  - باید به این نکته توجه داشت که در بعضی موارد تعیین مرز مشخصی برای متغیر ممکن است امکان پذیر نباشد.
  - مقدار نامی یا عادی متغیرهایی که از نوع تصادفی یا stochastic هستند، معمولا توسط مجموعه از توابع آماری قابل معرفی هستند:
    - Mean Value: $\mu_i = E\{Y_i(t)\}$
    - Variance: $\bar{\sigma}_i^2 = E\left\{[Y_i(t) - \mu_i]^2\right\}$

# آشکارسازی تغییرات با آستانه باینری

- در این صورت وقوع عیب در چنین سیستمی با محاسبه تغییرات قابل تشخیص است:

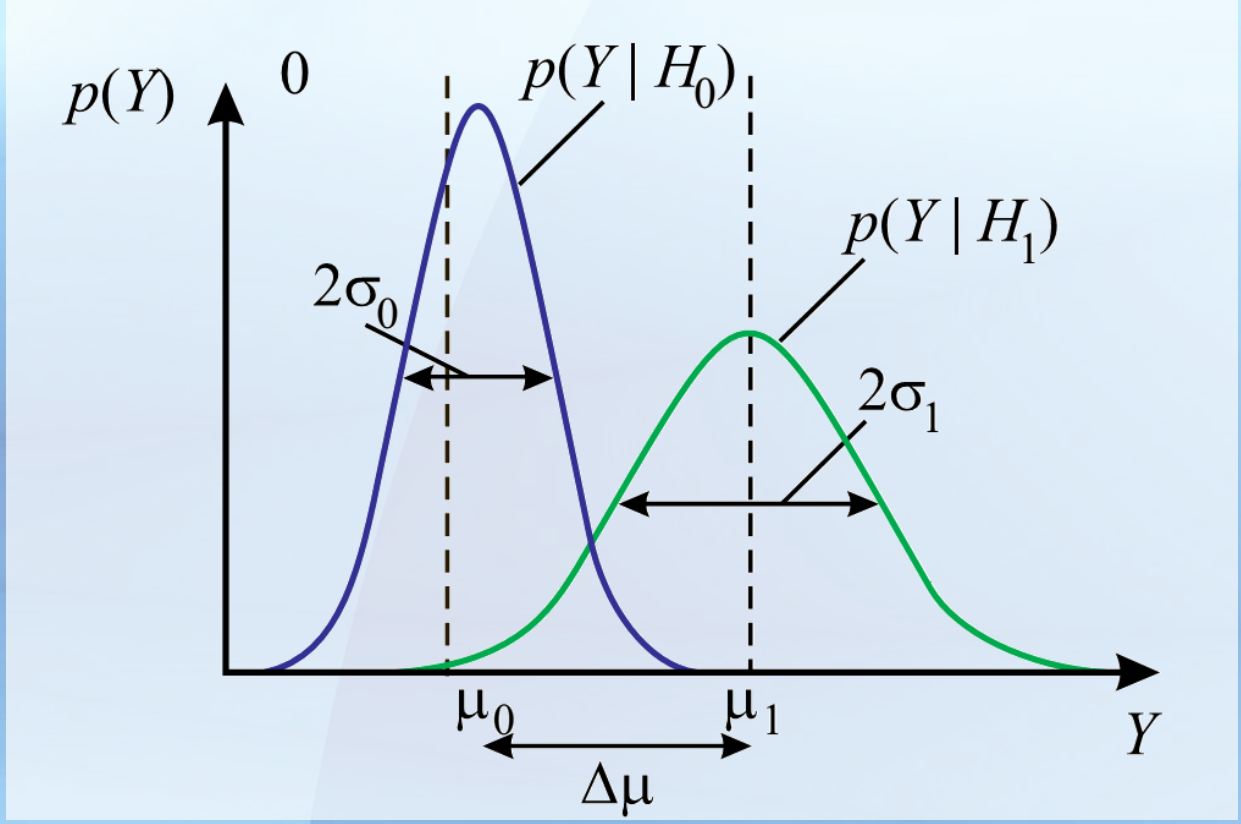
$$\Delta Y_i = E\{Y_i(t) - \mu_i\}$$

$$\Delta\sigma^2 = E\left\{[\sigma_i(t) - \bar{\sigma}_i]^2\right\}$$

– که در آن $t > t_F$ زمان بعد از وقوع عیب است.

# آشکارسازی تغییرات با آستانه باینری

- تابع چگالی احتمال (p.d.f.) گوسی
  - شرایط حالت عادی (0) / حالت معیوب (1)



# آشکارسازی تغییرات با آستانه باینری

- با توجه به شکل سه وضعیت ممکن است ایجاد شود:
  - تغییر در مقدار متوسط / انحراف از معیار ثابت
    $\mu_1 = \mu_0 + \Delta\mu$ $\sigma_1 = \sigma_0$
  - مقدار متوسط ثابت / تغییر در انحراف از معیار
    $\mu_1 = \mu_0$ $\sigma_1 = \sigma_0 + \Delta\sigma$
  - تغییر در مقدار متوسط / تغییر در انحراف از معیار
    $\mu_1 = \mu_0 + \Delta\mu$ $\sigma_1 = \sigma_0 + \Delta\sigma$

# آشکارسازی تغییرات با آستانه باینری

- مثال: فرض کنید می خواهیم عیب در یک سیستم را با تغییرات در مقدار میانگین بررسی کنیم. اگر pdf ها همپوشانی زیادی نداشته باشند، با استفاده از یک ترشلد ساده می توان عیب یابی کرد.

$$\Delta Y_{tol} = \kappa \sigma_0$$

- به ازای مقادیر بزرگ k مانند $k \geq 2$ عیب یابی به سادگی امکان پذیر است.
- در صورت کوچک شدن مقادیر k مانند $k \leq 1$ همپوشانی توابع توزیع زیاد شده و لذا امکان ایجاد اخطار کاذب زیاد است.

$$\Delta\mu = \mu_1 - \mu_0$$

- در این شرایط استفاده از تست های آماری ضروری خواهد بود.

# آستانه تطبیقی

- Adaptive thresholds

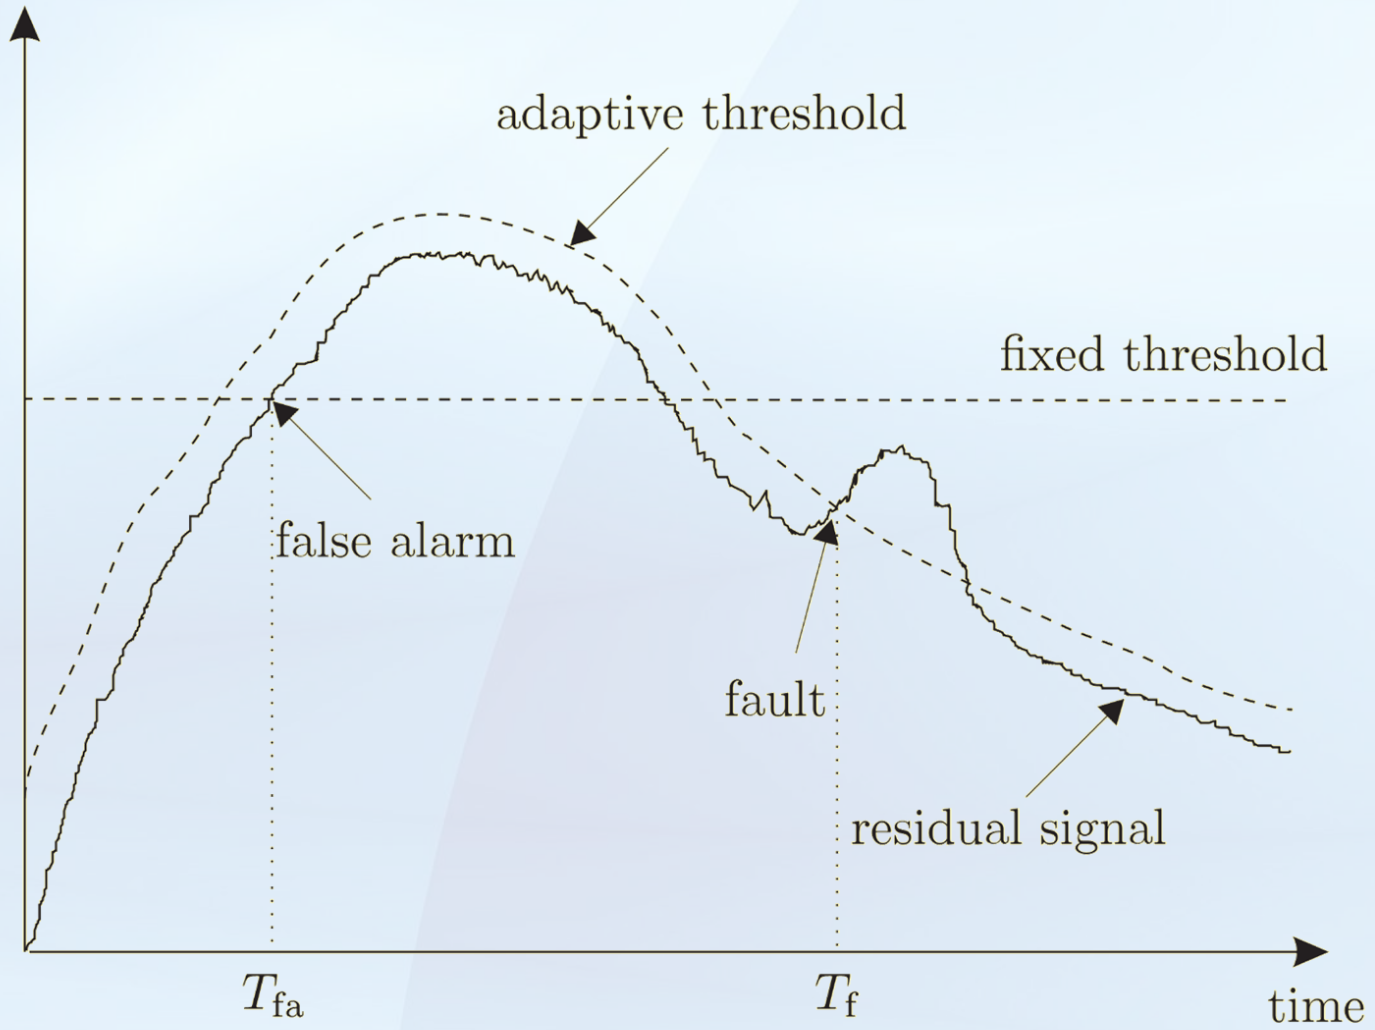
– عوامل مختلفی مانند:
  - اغتشاش
  - تغییر شرایط کاری / بار سیستم
  - نامعینی مدل ها

می تواند سبب ایجاد اخطار کاذب شود.

– یکی از روش های موثر برای پرهیز از این شرایط استفاده از آستانه ها تطبیقی است.

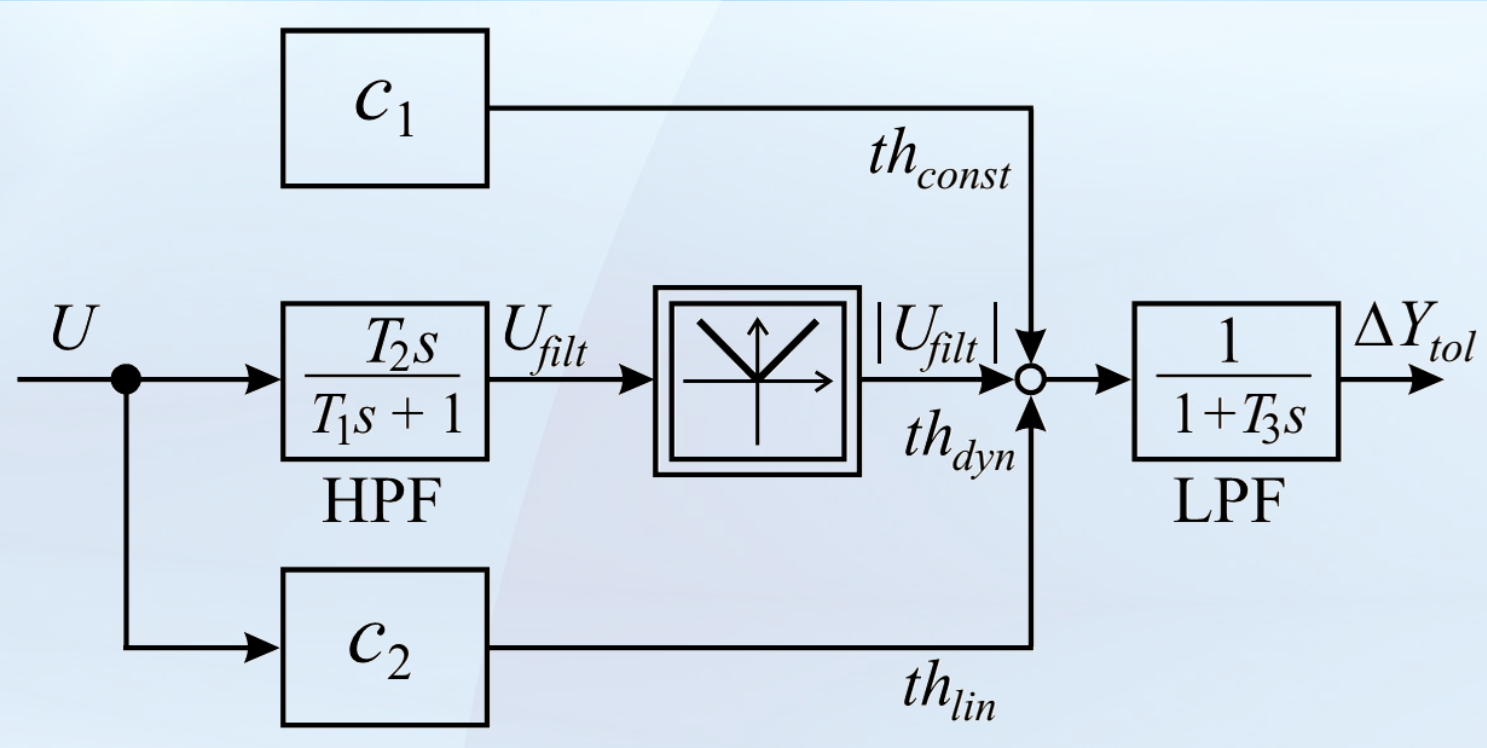
– استفاده از آستانه تطبیقی بخصوص روش های مدل- پایه بسیار موثر است.

# آستانه تطبیقی



# آستانه تطبیقی

- استفاده از یک فیلتر بالاگذر HPF ایده ساده است که می توان برای تولید آستانه تطبیقی از آن بهره برد.

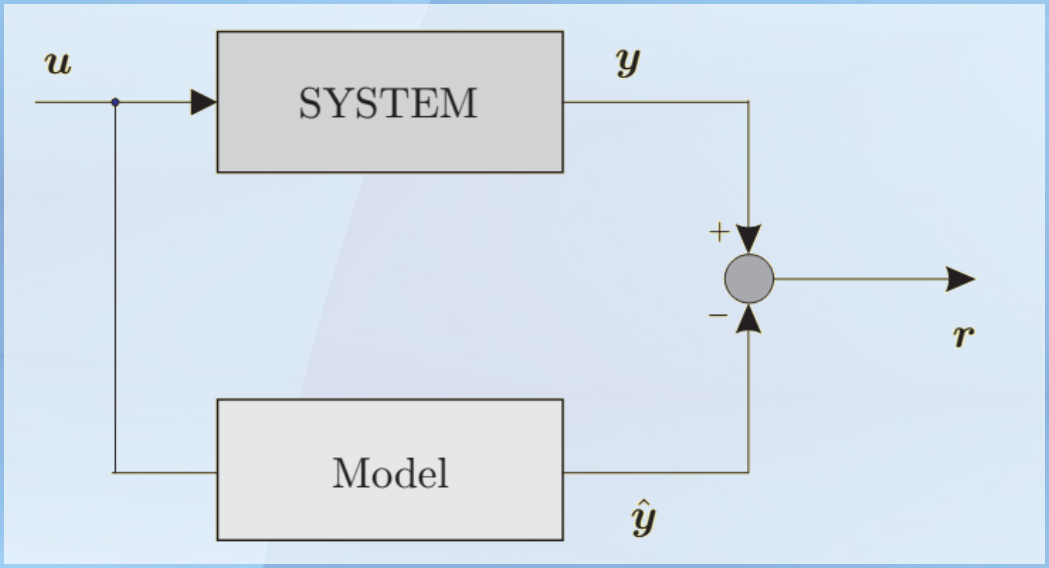


# آستانه تطبیقی

- HPF : فیلتر بالاگذر
- LPF : فیلتر پایین گذر برای نرم کردن خروجی ترشلد تطبیقی
- $T_1$ و $T_3$: بر اساس ثابت زمانی فرآیند
- $T_2/T_1$ : بر اساس نامعینی در دینامیک مدل سیستم

# آستانه تطبیقی

- محاسبه مقدار باقیمانده یا residual یک معیارمرسوم برای عیب بر اساس مدل فرآیند است.
- وجود نامعینی حاصل از مدلسازی، می تواند یکی از مهم ترین عوامل ایجاد اخطار کاذب باشد



# آستانه تطبیقی

- در روش های مدل پایه، می توان آستانه تطبیقی را بر اساس نامعینی مدل و مدل خطای سیستم بدست آورد:

$$\text{residual} = R = y - \hat{y}$$

– با تعریف مرکز ناحیه نامعینی

$$\text{UC} \approx \hat{y} + \hat{R}$$

$$\hat{R} = \text{The output of } \textit{error model}$$

– مقدار ترشلد تطبیقی:

$$\lambda = \hat{y} + \hat{R} \pm t_\beta s$$

$$t_\beta = N(0,\ 1)$$

# آستانه تطبیقی

- با فرض آنکه باقیماند به صورت یک عدد تصادفی به شکل $N(m,\nu)$ با میانگین $m$ و انحراف از معیار $\nu$ قابل تعریف باشد، مقدار $t_\beta$ باید در رابطه زیر صدق کند:

$$\beta = P\left(\left|\frac{r(k)-m}{\nu}\right| > t_\beta\right)$$

- که در آن $\beta$ یک مقدار اطمینان تعیین شده وابسته به تابع احتمال فوق است به صورتی که مقدار باقیمانده از مقدار $t_\beta$ به شکل $N(0,1)$ فراتر رود. مقدار $t_\beta$ از روی مقادیر جداول احتمال قابل تعیین شدن است.

# بررسی قابل اعتماد بودن

- Plausibility checks

– نظارت دقیق بر متغیرهای اندازه گیری گاهی بررسی قابل اعتماد بودن مقدار متغیرهای تعیین شده، انجام می پذیرد.

– مقادیر اندازه گیری شده بر اساس اعتبار، مناسبت و سازگاری با سایر مقادیر اندازه گیری شده ارزیابی می شوند.

– در صورت استفاده از یک سیگنال، باید مقدار آن در بازه معین و قابل قبول قرار گیرد.

– در صورت وجود متغیرهای مختلف، با استفاده از روابط منطقی، وضعیت عملکرد سیستم ارزیابی می شود.

# بررسی قابل اعتماد بودن

- شکل کلی آن به صورت زیر خواهد بود:

$$\text{IF } [Y_{1min} < Y_1(t) < Y_{1max}] \text{ THEN } [Y_{2min} < Y_2(t) < Y_{2max}]$$

- برای مثال، رابطه فشار و سرعت یک پمپ:

$$\text{IF } [1000 \text{ rpm} < n < 3000 \text{ rpm}] \text{ THEN } [3 \text{ bar} < p < 8 \text{ bar}]$$

- بررسی قابل اعتماد بودن بر اساس شرایط کاری:

$$\text{IF } [\text{Operating condition 1}] \text{ THEN } [Y_{3min} < Y_3(t) < Y_{3max}]$$

# بررسی قابل اعتماد بودن

- می توان شرایط مختلف را بر اساس ترکیب منطقی AND و یا OR به هم مرتبط نمود.

- به عنوان مثال، اگر فشار روغن، دور موتور و دمای آب خنک کننده برای بررسی وضعیت عیب در یک سیستم بکار گرفته شود:

$$\text{IF } [n < 1500\,\text{rpm}] \text{ AND } [\vartheta_{\text{H20}} < 50°\text{C}] \text{ THEN } [3\,\text{bar} < p_{oil} < 5\,\text{bar}]$$

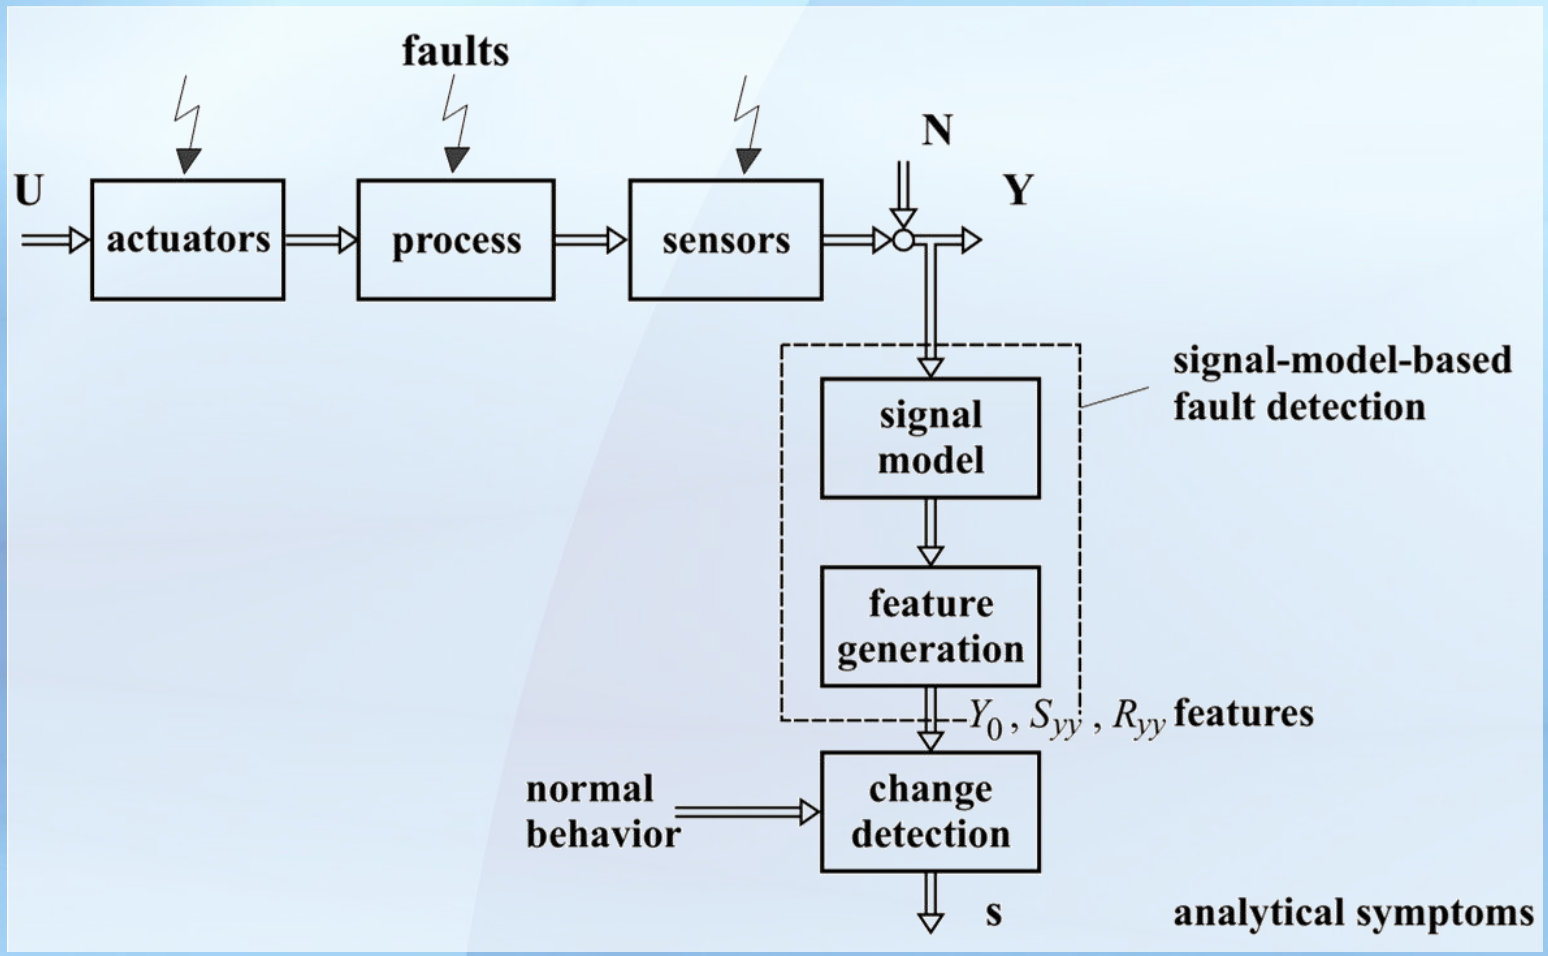
# روش های تحلیل سیگنال

- بسیاری از سیگنالهای اندازه گیری شده دارای نوسان با ماهیت نوسانی (Harmonic) یا اتفاقی (Stochastic) یا ترکیبی از آنها باشد.

- اگر تغییرات ایجاد شده در سیگنال وابسته به عیب سیستم باشد با استفاده از روش های عیب یابی مدل سیگنال یا Signal-model-based قابل استفاده است.

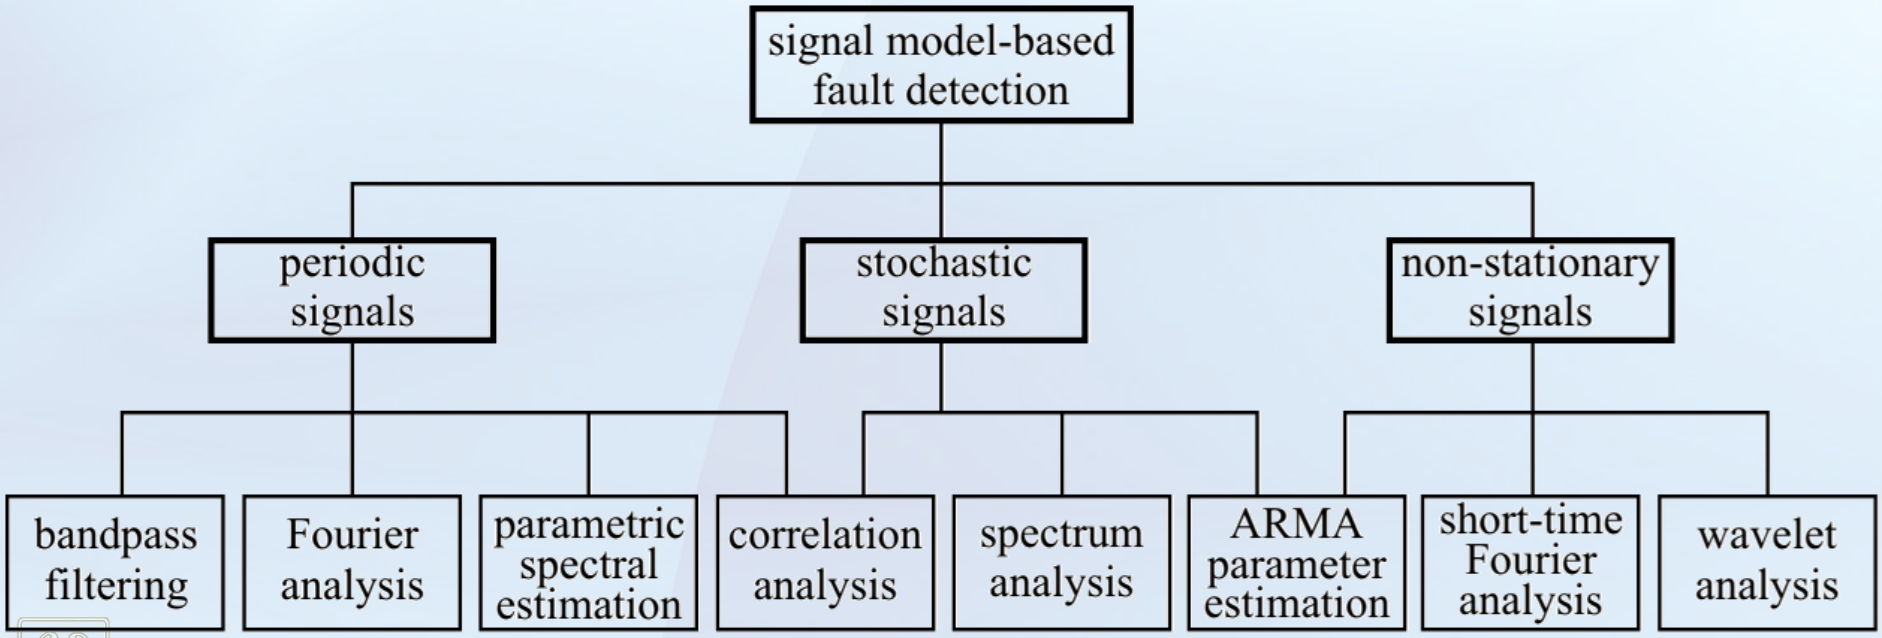
# روش های تحلیل سیگنال

- ایده کلی روش عیب یابی بر اساس مدل سیگنال:

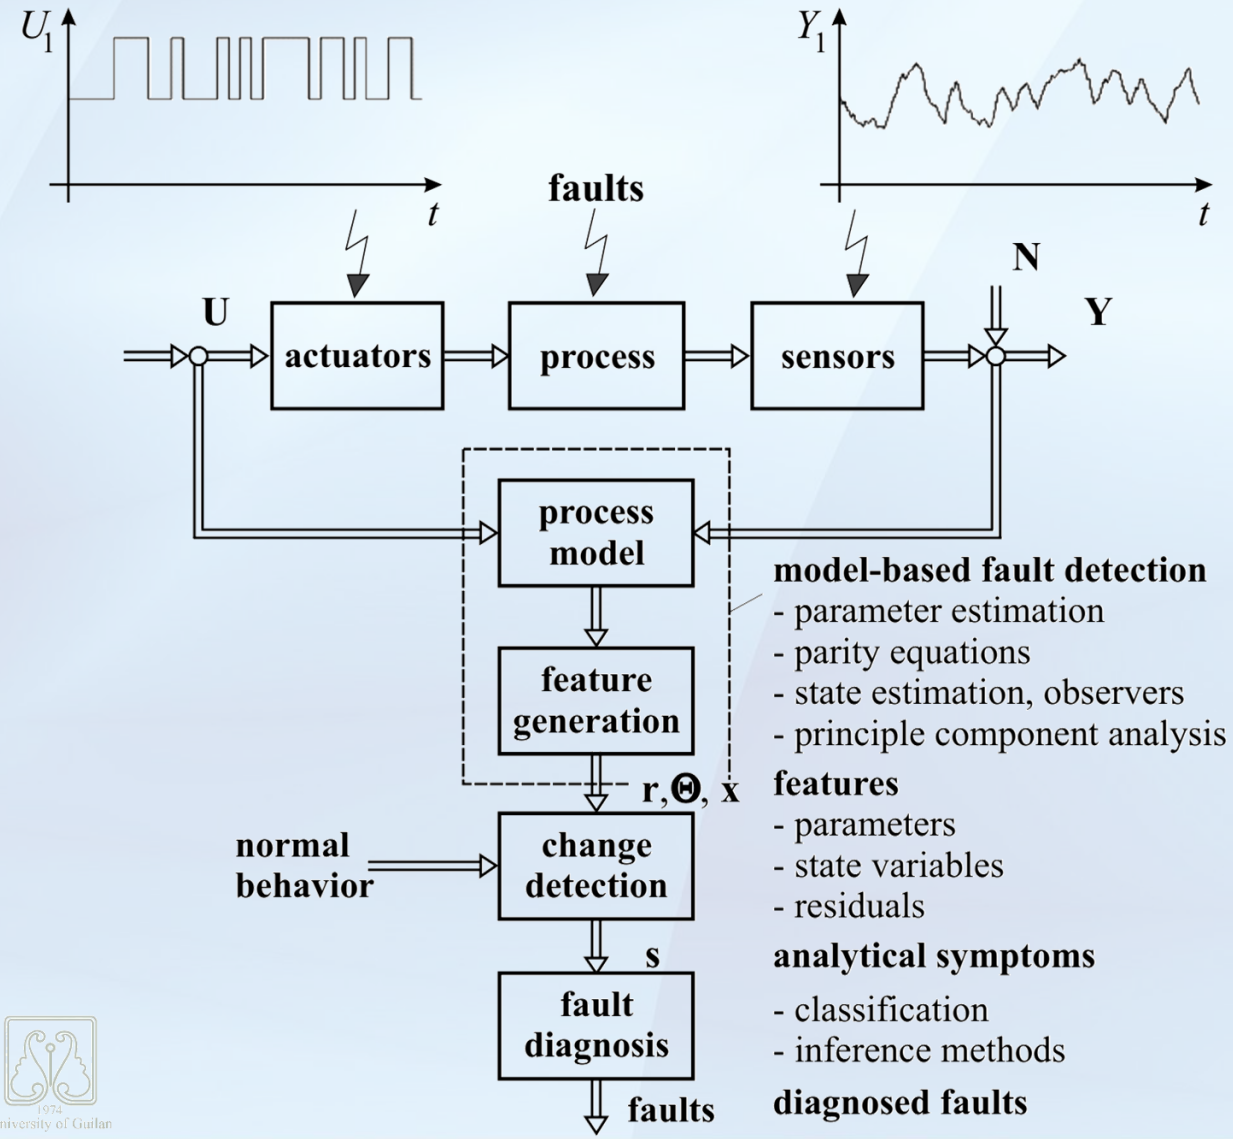


# عیب یابی بر اساس مدل سیگنال

- روش های بسیار متعددی برای عیب یابی سیستم ها بر اساس مدل سیگنال وجود دارد ولی به صورت کلی به سه دسته برای سیگنالهای پریودیک، سیگنالهای تصادفی و سیگنالهای غیرپایا تقسیم می شود:



# عیب یابی بر اساس مدل فرآیند




- یکی از روش های بسیار مهم در عیب یابی سیستم های صنعتی استفاده از مدل فرآیند است.
- ایده کلی این روش در شکل نشان داده شده است:

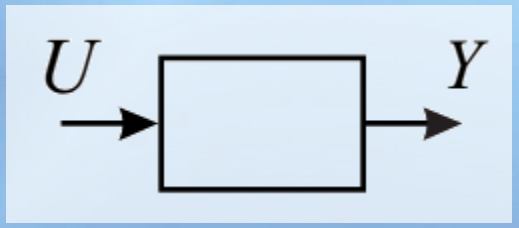
University of Guilan

# عیب یابی بر اساس مدل فرآیند

- در این روش با توجه به مقدار U، ورودی سیستم و مقدار Y، خروجی سیستم، مقدار باقیماند یا residual با مقایسه مقادیر خروجی مدل و سیگنال اندازه گیری شده، محاسبه می شود.
- مقدار باقیماند برای تعیین ویژگی ها یا Features استفاده می شوند.
- میزان انحراف ویژگی ها نسبت به مقدار نامی (عادی یا نرمال) آنها می تواند نشانگر میزان عیب در سیستم باشد.

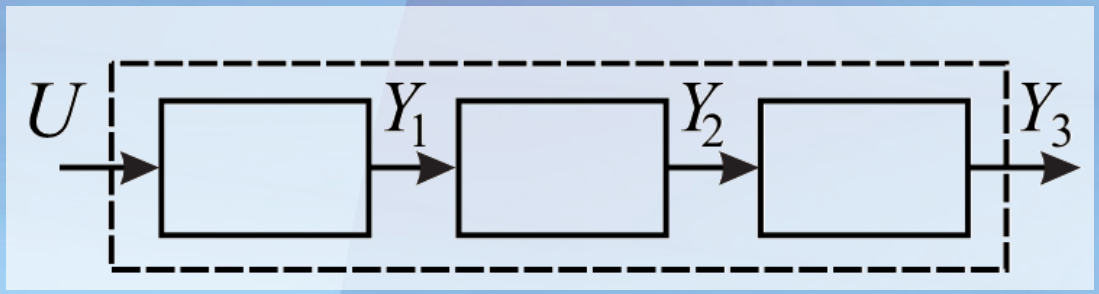
# عیب یابی بر اساس مدل فرآیند

- باید به این نکته توجه داشت که میزان پیچیدگی مدل فرآیند بسیار وابسته به ساختار اصلی سیستم است.
- چهار ساختار زیر در سیستم ها فرآیندی قابل مشاهده است:

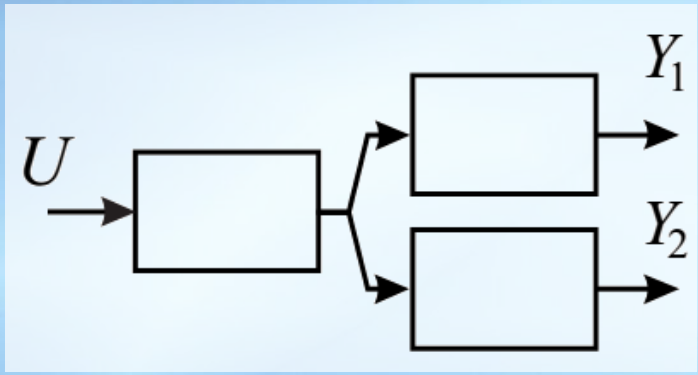



– یک ورودی - یک خروجی (SISO)

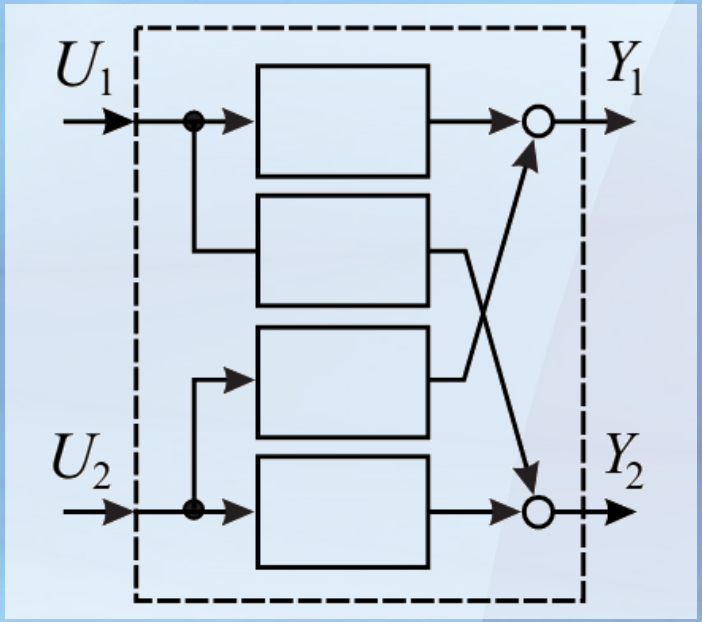
– یک ورودی - یک خروجی با متغیر میانی



# عیب یابی بر اساس مدل فرآیند




- یک ورودی – چند خروجی (SIMO)

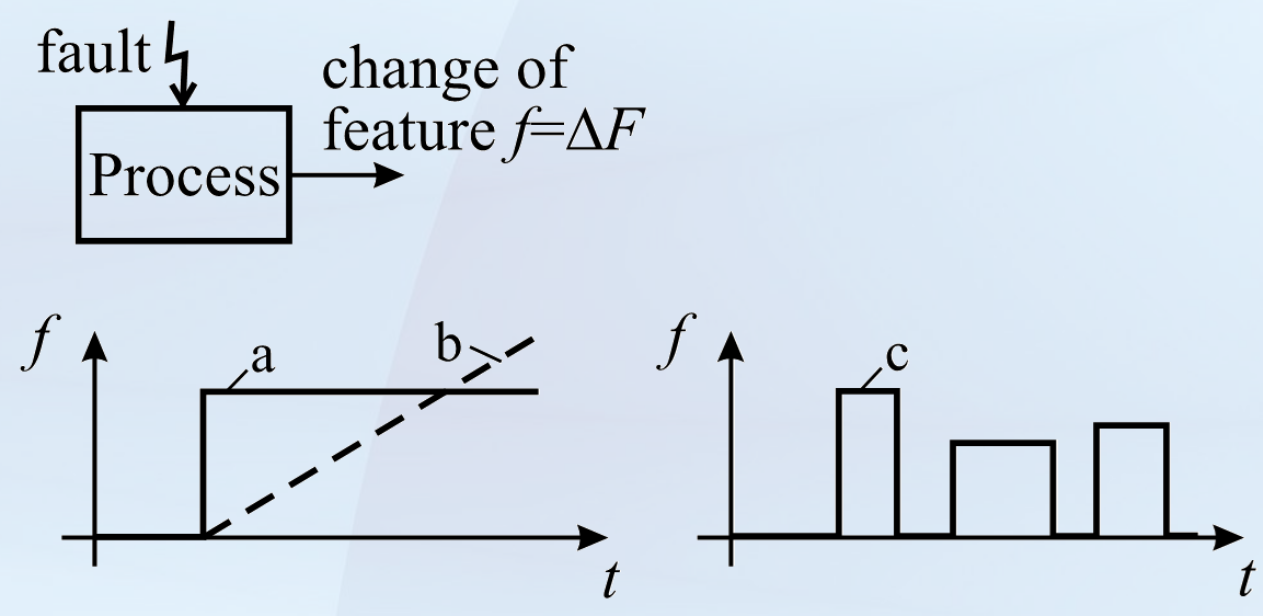



- چند ورودی – چند خروجی (MIMO)

- چند ورودی- یک خروجی (MISO) یا سیستم های افزونه (Redundant)

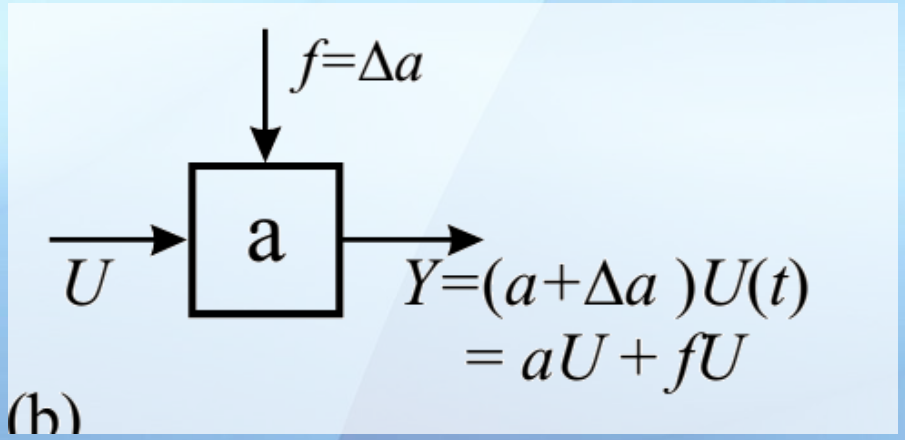
# مدل فرآیند و مدل عیب

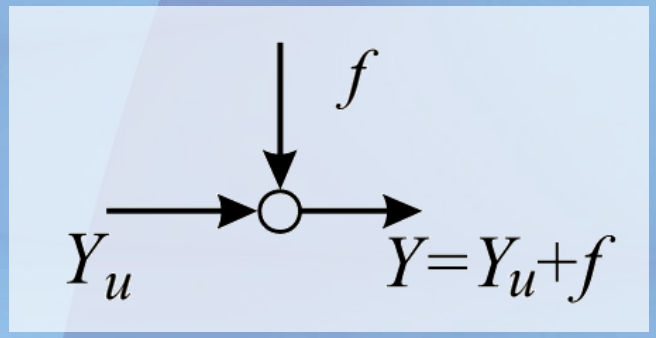
- عیب یک سیستم می توان به شکل های متفاوتی ظاهر شود:
  - عیب ناگهانی (Abrupt fault) یا پله ای
  - عیب انحرافی (Drift-like)
  - عیب متناوب (Intermittent)



# مدل فرآیند و مدل عیب

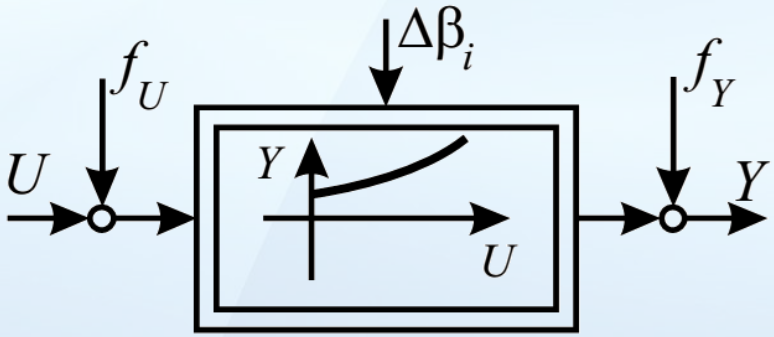
- متغیر سیستم به دو شکل تحت تاثیر عیب قرار می گیرد:
  - نوع ضربی
  - نوع جمع



# مدل فرآیند و مدل عیب

- مدل های استاتیک: تهیه مدل بر اساس حالت ماندگار سیستم




Measured signals: $U(t)$, $Y(t)$

Basic equation:

$$Y = \beta_0 + \beta_1 U + \beta_2 U^2 + \ldots + \beta_q U^q \rightarrow Y = \boldsymbol{\psi}_S^T \boldsymbol{\Theta}_S$$

$$\boldsymbol{\Theta}_S^T = [\beta_0 \beta_1 \ldots \beta_q] \qquad \boldsymbol{\psi}_S^T = [1\ U\ U^2 \ldots U^q]$$

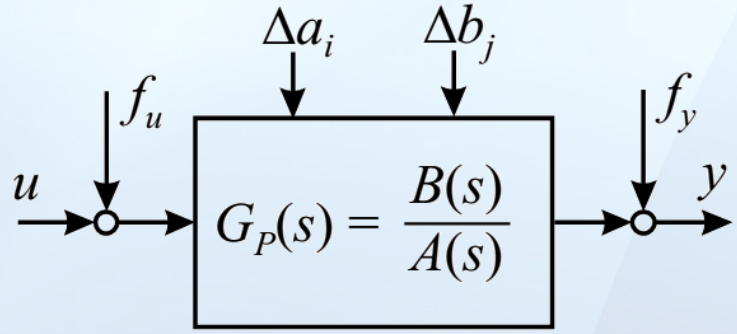
Additive faults: $f_U$ input fault; $f_Y$ output fault

Multiplicative faults: $\Delta\beta_i$ parameter faults

# مدل فرآیند و مدل عیب

- مدل های تابع تبدیل

Input/output model




Measured signals:

$$y(t) = Y(t) - Y_{00}\,;\; u(t) = U(t) - U_{00}$$

Basic equations:

$$y(t) + a_1 y^{(1)}(t) + \ldots + a_n y^{(n)}(t)$$
$$= b_0 u(t) + b_1 u^{(1)}(t) + \ldots + b_m u^{(m)}(t)$$

$$y(t) = \boldsymbol{\psi}^T(t)\,\boldsymbol{\Theta}$$

$$\boldsymbol{\Theta}^T = [\, a_1 \ldots a_n \; b_0 \ldots b_m \,]$$

$$\boldsymbol{\psi}^T = [\, -y^{(1)}(t) \ldots -y^{(n)}(t) \quad u(t) \ldots u^{(m)}(t) \,]$$

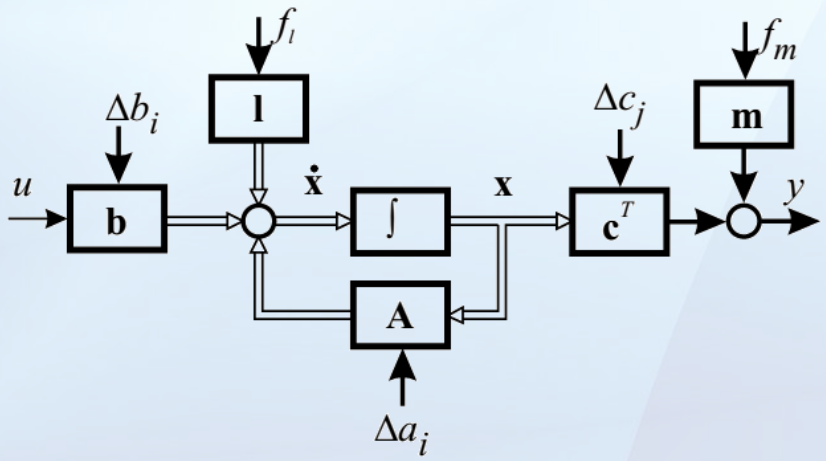
Additive faults:
$f_u$ input fault; $f_y$ output fault

Multiplicative faults:
$\Delta a_i$, $\Delta b_j$ parameter faults

# مدل فرآیند و مدل عیب

- مدلهای فضای حالت

State-space model




$$\dot{\mathbf{x}}(t) = \mathbf{A}\,\mathbf{x}(t) + \mathbf{b}u(t)$$
$$y(t) = \mathbf{c}^T\,\mathbf{x}(t)$$

$$\mathbf{A} = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & -a_1 \\ 1 & 0 & -a_2 \\ \vdots & \vdots & \vdots \end{bmatrix}$$

$$\mathbf{b}^T = [\, b_0 \quad b_1 \quad \cdots \,]$$

$$\mathbf{c}^T = [\, 0 \quad 0 \quad \cdots \quad 1 \,]$$

$f_l$ input or state-variable fault

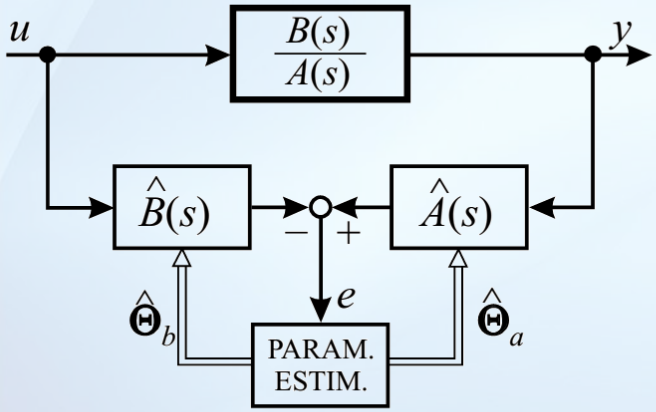
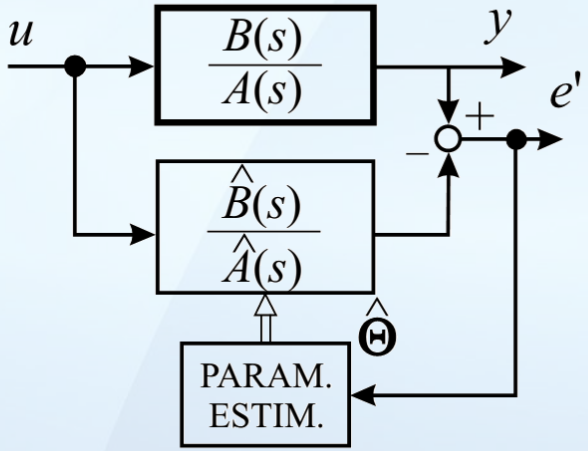
$f_m$ output fault

$\Delta\mathbf{A}$, $\Delta\mathbf{b}$, $\Delta\mathbf{c}$ parameter faults

# عیب یابی بر اساس تخمین پارامتر

- برای عیب یابی بر اساس مدل فرآیند، تعیین ساختار و پارامترهای مدل ضروری است.
- بر اساس سیگنال ورودی- خروجی و ساختار اصلی سیستم، می توان پارامترهای مدل را به صورت برخط online محاسبه و تعیین نمود.
- این می تواند به شکل پیوسته زمانی (پاسخ ضربه، معادلات دیفرانسیل، پاسخ فرکانسی) و یا از نوع گسسته زمانی (پاسخ ضربه، معادلات تفاضلی، تابع تبدیل Z) باشد.

# عیب یابی بر اساس تخمین پارامتر

| Minimization of equation error | Minimization of output error |
|---|---|
|  |  |
| Loss function: $V = \Sigma\, e^2(k)$<br>Method:<br>• non-recursive<br>$\hat{\Theta} = [\Psi^T\Psi]^{-1}\Psi^T\mathbf{y}$<br>• recursive<br>$\hat{\Theta}(k+1) = \hat{\Theta}(k) + \gamma(k)e(k+1)$ | $V = \Sigma\, e'^2(k)$<br>• nonlinear parameter optimization<br>• recursive form<br>$\hat{\Theta}(\nu+1) = \hat{\Theta}(\nu) + \Gamma(\nu)\frac{\partial V}{\partial \Theta}(\nu)$ |

Symptoms:
- model parameters $\Delta\hat{\Theta}(j) = \hat{\Theta}(j) - \Theta_0$
- process coefficients $\hat{\mathbf{p}} = f^{-1}[\Theta]$ $\Delta\mathbf{p}(j) = \hat{\mathbf{p}}(j) - \mathbf{p}_0$

– میزان تغییرات در پارامتر سیستم می تواند به عنوان نشانه عیب شناخته شود.

University of Guilan

# عیب یابی بر اساس مشاهده گر

- در صورت مشخص بودن پارامترهای یک سیستم، می توان از مشاهده گرها برای عیب یابی سیستم ها استفاده نمود:
  - مشاهده گرهای حالت
  - مشاهده گرهای خروجی
  - تخمین حالت

# مشاهده گرهای حالت

- یک مشاهده گر، با تحریک یک خروجی
- بانکی از مشاهده گر ها، با تحریک تمامی خروجی ها
- بانکی از مشاهده گر ها، با تحریک یک خروجی
- بانکی از مشاهده گر ها، با تحریک تمامی خروجی ها به استثنای یک خروجی

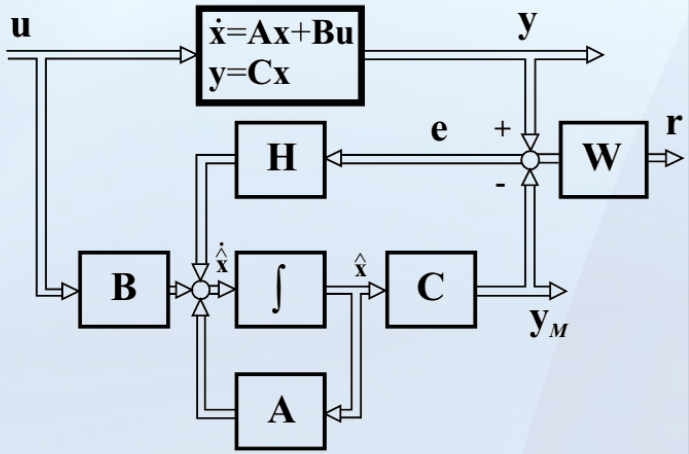
# مشاهده گرهای حالت

Process model:

$\dot{\mathbf{x}}(t) = \mathbf{A}\,\mathbf{x}(t) + \mathbf{B}\,\mathbf{u}(t) + \mathbf{F}\,\mathbf{v}(t) + \mathbf{L}\,\mathbf{f}_L(t)$

$\mathbf{y}(t) = \mathbf{C}\,\mathbf{x}(t) + \mathbf{N}\,\mathbf{n}(t) + \mathbf{M}\,\mathbf{f}_M(t)$

$\mathbf{v}(t)$, $\mathbf{n}(t)$: disturbance signals; $\mathbf{f}_L$, $\mathbf{f}_M$: additive fault signals




Observer equations:

$\dot{\hat{\mathbf{x}}}(t) = \mathbf{A}\,\hat{\mathbf{x}}(t) + \mathbf{B}\,\mathbf{u}(t) + \mathbf{H}\,\mathbf{e}(t)$

$\mathbf{e}(t) = \mathbf{y}(t) - \mathbf{C}\,\hat{\mathbf{x}}(t)$

Residuals:

- $\Delta\mathbf{x}(t) = \mathbf{x}(t) - \mathbf{x}_0(t)$
- $\mathbf{e}(t)$
- $\mathbf{r}(t) = \mathbf{W}\,\mathbf{e}(t)$

Special observers:

– fault-sensitive filters
(**H** such that $\mathbf{r}(t)$ defin. direct.)

– dedicated observers
(for different sensor outputs)

# مشاهده گرهای خروجی

- در صورتی که مقادیر حالت ها مورد نیاز نباشد می توان از مشاهده گر خروجی بهره برد.

- در این روش سیستم عیب یابی بر اساس مدلی با پارامترهای ثابت عمل کرده، و مقادیر حالت ها به دلیل وجود خطای خروجی توسط کنترلر اصلاح می شوند.

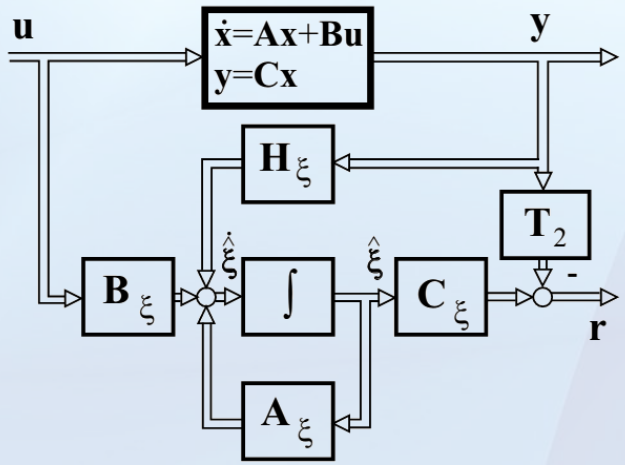
# مشاهده گرهای خروجی

Process model:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\,\mathbf{x}(t) + \mathbf{B}\,\mathbf{u}(t) + \mathbf{F}\,\mathbf{v}(t) + \mathbf{L}\,\mathbf{f}_L(t)$$

$$\mathbf{y}(t) = \mathbf{C}\,\mathbf{x}(t) + \mathbf{N}\,\mathbf{n}(t) + \mathbf{M}\,\mathbf{f}_M(t)$$

$\mathbf{v}(t)$, $\mathbf{n}(t)$: disturbance signals; $\mathbf{f}_L$, $\mathbf{f}_M$: additive fault signals




$$\dot{\hat{\boldsymbol{\xi}}}(t) = \mathbf{A}_\xi\,\hat{\boldsymbol{\xi}}(t) + \mathbf{B}_\xi\,\mathbf{u}(t) + \mathbf{H}_\xi\,\mathbf{y}(t)$$

$$\boldsymbol{\eta}(t) = \mathbf{C}_\xi\,\hat{\boldsymbol{\xi}}(t)$$

$\boldsymbol{\xi}(t) = \mathbf{T}_1\,\mathbf{x}(t)$: transformation

$$\boldsymbol{\xi}(t) = \dot{\hat{\boldsymbol{\xi}}}(t) - \mathbf{T}_1\,\dot{\mathbf{x}}(t)$$

$$\mathbf{r}(t) = \mathbf{C}_\xi\,\boldsymbol{\xi}(t) - \mathbf{T}_2\mathbf{M}f_M(t)$$

– independent of $\mathbf{x}(t)$, $\mathbf{u}(t)$, $\mathbf{v}(t)$

– dependent on $\mathbf{f}_L(t)$, $\mathbf{f}_M(t)$

Design equations:

$$\mathbf{T}_1\mathbf{A} - \mathbf{A}_\xi\mathbf{T}_1 = \mathbf{H}_\xi\mathbf{C}$$

$$\mathbf{B}_\xi = \mathbf{T}_1\mathbf{B}$$

$$\mathbf{T}_1\mathbf{V} = \mathbf{0}$$

$$\mathbf{C}_\xi\mathbf{T}_1 - \mathbf{T}_2\mathbf{C} = \mathbf{0}$$

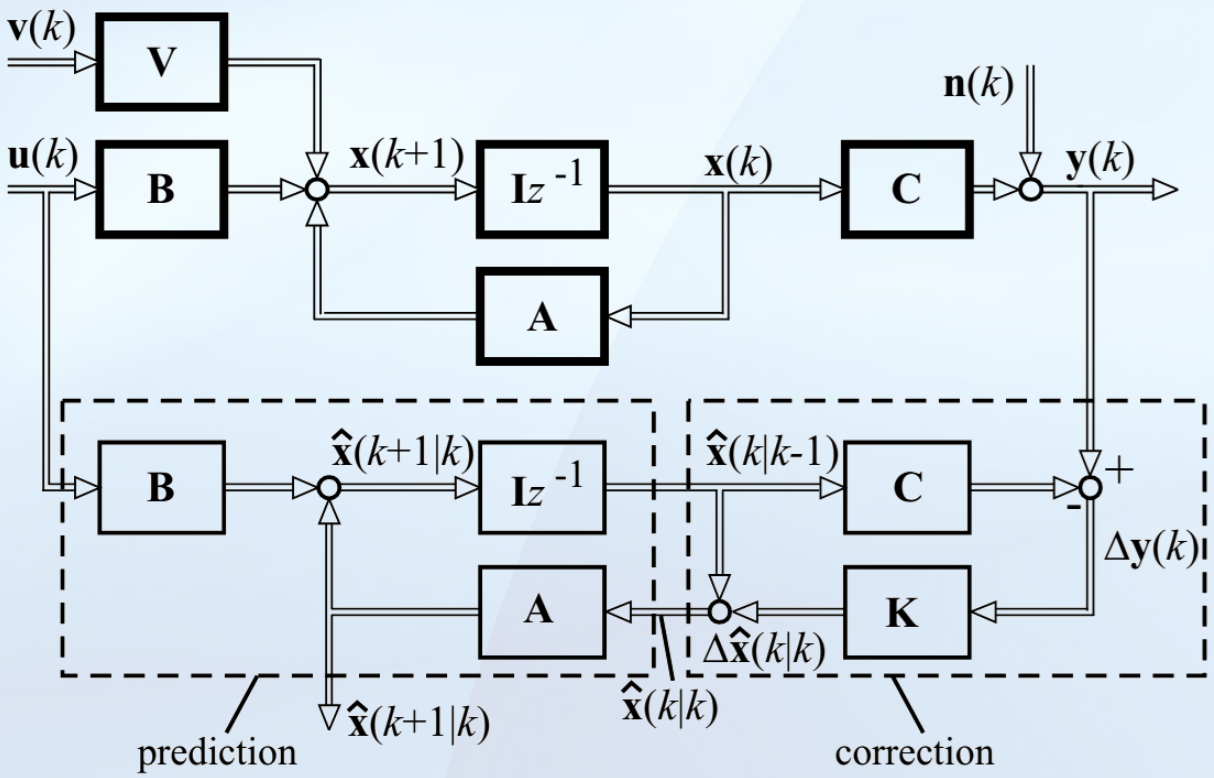
# تخمین حالت

- استفاده از تخمین گرهای حالت مانند Kalman-filter همانند مشاهده گرهای حالت است.

- از این تخمین گرها زمانی استفاده می شود که سیستم تحت تاثیر نویز و یا اغتشاش تصادفی باشد.

- تخمین گرهای حالت در عیب یابی سنسورها نیز کاربرد دارند.

# تخمین حالت: فیلتر کالمن




Process models:

$\mathbf{x}(k+1) = \mathbf{A}\,\mathbf{x}(k) + \mathbf{B}\,\mathbf{u}(k) + \mathbf{V}\,\mathbf{v}(k)$

$\mathbf{y}(k) = \mathbf{C}\,\mathbf{x}(k) + \mathbf{n}(k)$

$\mathbf{v}(k)$, $\mathbf{n}(k)$: stochastic disturbances with known covariance matrices $\mathbf{M}$ and $\mathbf{N}$

# تخمین حالت: فیلتر کالمن

- معادلات حالت

State estimation equations:

- prediction: $\hat{\mathbf{x}}(k+1|k) = \mathbf{A}\,\hat{\mathbf{x}}(k|k) + \mathbf{B}\,\mathbf{u}(k)$
- correction : $\hat{\mathbf{x}}(k|k) = \hat{\mathbf{x}}(k|k\text{-}1) + \overline{\mathbf{K}}[\mathbf{y}(k) - \mathbf{C}\hat{\mathbf{x}}(k|k-1)]$
- filter gain: $\overline{\mathbf{K}} = \mathbf{P}^{-}\mathbf{C}^{\mathrm{T}}[\mathbf{C}\,\mathbf{P}^{-}\mathbf{C}^{\mathrm{T}} + \mathbf{N}]^{-1}$
- error covariance matrix Riccati equation:

$$\mathbf{P}^{-}(k+1) = \mathbf{A}\mathbf{P}^{-}(k)\,\mathbf{A}^{\mathrm{T}} - \mathbf{A}\mathbf{P}^{-}(k)\,\mathbf{C}^{\mathrm{T}}[\mathbf{C}\mathbf{P}^{-}(k)\,\mathbf{C}^{\mathrm{T}} + \mathbf{N}]^{-1}\mathbf{C}\mathbf{P}^{-}(k)^{\mathrm{T}}\mathbf{A} + \mathbf{V}\mathbf{M}\,\mathbf{V}^{\mathrm{T}}$$

Residuals: $\Delta\hat{\mathbf{x}}(k+1|k)$

$$\Delta\mathbf{y}(k) = \mathbf{e}\,(k)$$

# معادلات برابری

- Parity equations

- یک روش تشخیص عیب مبتنی بر مدل، در نظر گرفتن یک مدل به صورت ثابت و مقایسه خروجی سیستم معیوب با خروجی آن است به صورتی که مقدار باقیمانده به شکل زیر بدست آید:

$$r'(s) = [G_p(s) - G_M(s)]\, u(s)$$

# معادلات برابری

- در صورتی که:

$$G_p(s) = G_M(s)$$

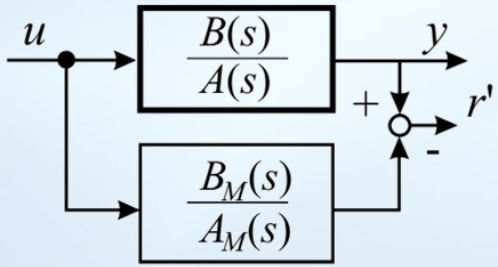
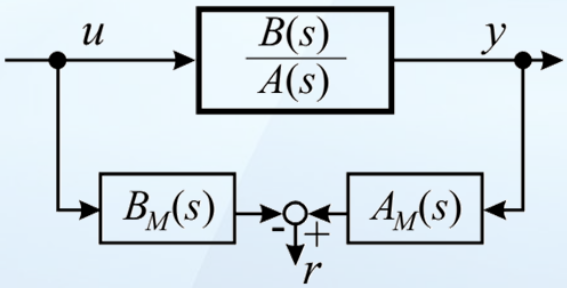
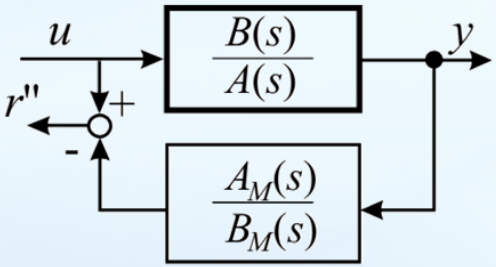
در این صورت با اضافه کردن خطای خروجی، مقدار عیب به صورت زیر خواهد بود:

$$r'(s) = G_p(s)\ f_u(s) + f_y(s)$$

در جدول بعد، نحوه تعیین باقیمانده ها بر اساس معادلات برابری نشان داده شده است.

# معادلات برابری

- Fault detection with different forms of parity equations

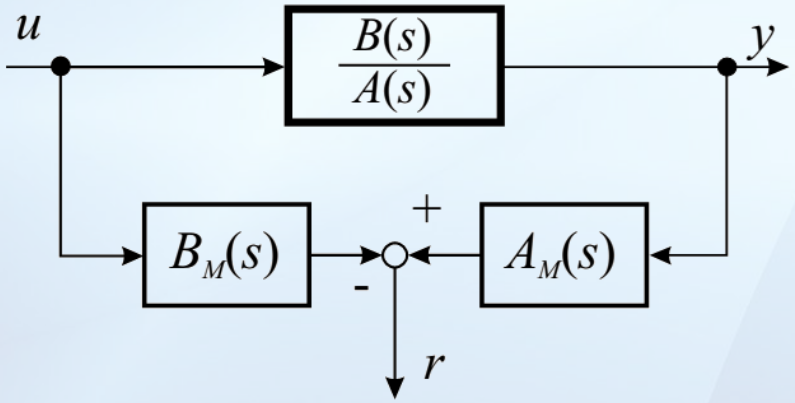
| Output error | Equation error | Input error |
|---|---|---|
|  |  |  |
| Parity equations:<br>$r'(s) = y(s) - \frac{B_M(s)}{A_M(s)}\, u(s)$<br>$r'(t) = \psi_r'^T(t)\Theta_{Mr} + \psi_a^T(t)\Theta_{Ma} - \psi_b^T(t)\Theta_{Mb}$ | $r(s) = A_M(s)\, y(s) - B_M\, u(s)$<br>$r(t) = \psi_a^T(t)\, \Theta_{Ma} - \psi_b^T \Theta_{Mb}$ | $r''(s) = u(s) - \left(\frac{A_M(s)}{B_M(s)}\right) y(s)$<br>$r''(t) = \psi_b''^T(t)\Theta_{Mb}'' - \psi_a^T(t)\Theta_{Ma}$ |
| $B_M(s) = b_0 + b_1 s + \ldots + b_m s^m$<br>$A_M(s) = 1 + a_1 s + \ldots + a_n s^n$<br>$\Theta_{Mr}^T = [\,1\ a_1\ a_2 \ldots\ a_n\,]$<br>$\psi_r'^T = [\,y\ y^{(1)}\ y^{(2)} \ldots\ y^{(n)}\,]$ | $\Theta_{Mb}^T = [\,b_0\ b_1 \ldots\ b_m\,]$<br>$\Theta_{Ma}^T = [\,1\ a_1 \ldots\ a_n\,]$<br>$\psi_b^T = [\,u\ u^{(1)}\ u^{(2)} \ldots\ u^{(m)}\,]$<br>$\psi_a^T = [\,y\ y^{(1)}\ y^{(2)} \ldots\ y^{(n)}\,]$ | $\Theta_{Mb}''^T = \frac{1}{b_0}[\,1\ b_1\ b_2 \ldots\ b_m\,]$<br>$\psi_b''^T = [\,u\ u^{(1)}\ u^{(2)} \ldots\ u^{(m)}\,]$ |

# معادلات برابری

- می توان از معادلات برابری برای تعیین عیب در سیستم های چند متغیره نیز استفاده نمود.
- معادلات برابری در فرم چندجمله ای های تابع تبدیل و یا فرم فضای حالت می تواند بکار گرفته شوند.
- در شکل فضای حالت، از ماتریسی همانند W می توان بهره برد تا تنها خروجی یا حالت های مشخصی برای محاسبه باقیمانده در دسترس باشند.

# معادلات برابری

## Input/output model, equation error




$$B_M(s) = b_0 + b_1 s + \ldots + b_m s^m$$

$$A_M(s) = 1 + a_1 s + \ldots + a_n s^n$$

$$\Theta_{Mb}^T = [\, b_0\, b_1 \ldots\, b_m \,]$$

$$\Theta_{Ma}^T = [\, 1\; a_1\, a_2 \ldots\, a_n \,]$$

$$\psi_b^T = [\, u\; u^{(1)}\, u^{(2)} \ldots\, u^{(m)} \,]$$

$$\psi_a^T = [\, y\, y^{(1)} \ldots\, y^{(n)} \,]$$

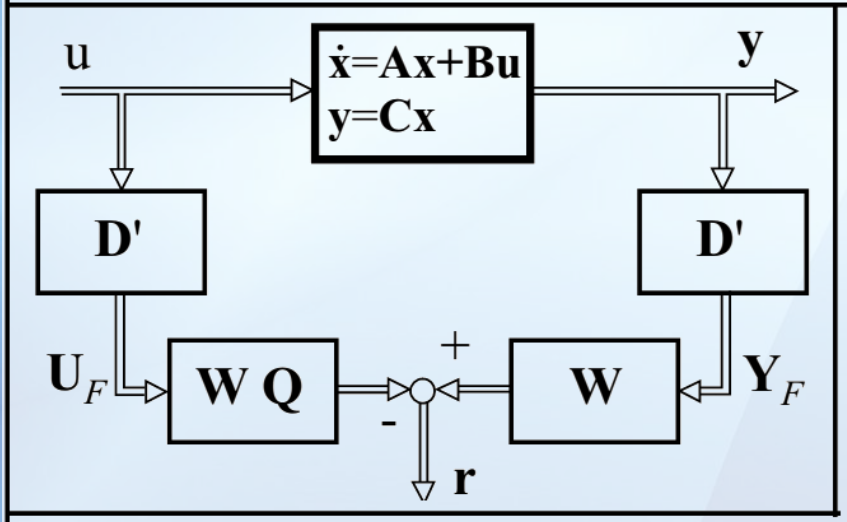
Parity equations:

$$r(s) = A_M(s)y(s) - B_M(s)u(s)$$

$$r(t) = \psi_a^T(t)\Theta_{Ma} - \psi_b^T(t)\Theta_{Mb}$$

# معادلات برابری

## State space model




$$\mathbf{D'u} = [\, u\, u^{(1)} \ldots u^{(m)} \,]^T = \mathbf{U}_F$$

$$\mathbf{D'y} = [\, \mathbf{y}\, \mathbf{y}^{(1)} \ldots \mathbf{y}^{(n)} \,]^T = \mathbf{Y}_F$$

$$\mathbf{T} = [\, C \;\; CA \;\; CA^2 \ldots \,]^T$$

$$\mathbf{Q} = \begin{bmatrix} 0 & 0 & 0 \ldots. \\ CB & 0 & 0 \\ CAB & CB & 0 \\ \mathrm{M} & & \end{bmatrix}$$

$$\mathbf{Y}_F(t) = \mathbf{T}\,\mathbf{X}(t) + \mathbf{Q}\,\mathbf{U}_F(t)$$

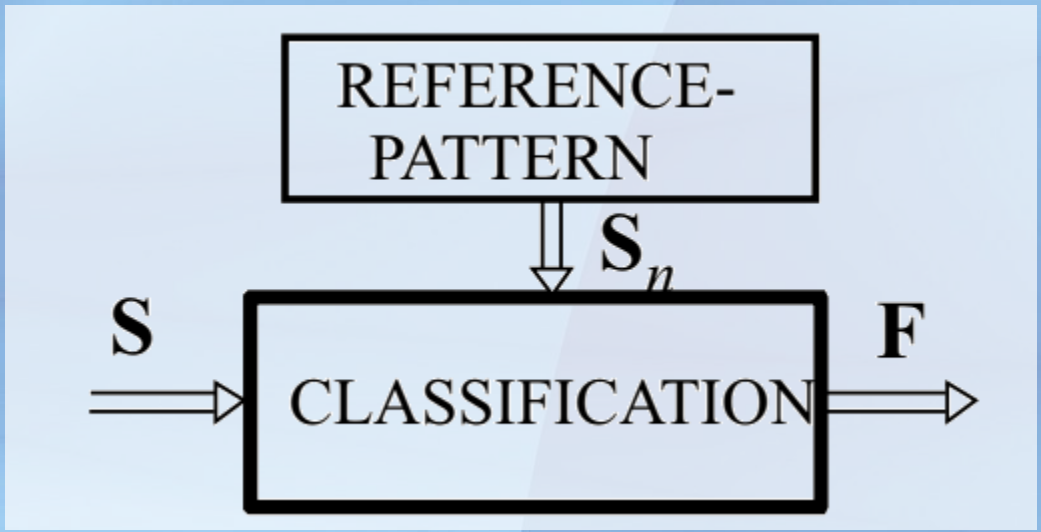
$$\mathbf{W}\,\mathbf{Y}_F(t) = \mathbf{W}\,\mathbf{T}\,\mathbf{x}\,(t) + \mathbf{W}\,\mathbf{Q}\,\mathbf{U}_F(t)$$

$$\mathbf{W}\,\mathbf{T} = 0$$

$$\mathbf{r}\,(t) = \mathbf{W}(\mathbf{Y}_F(t) - \mathbf{Q}\,\mathbf{U}_F(t))$$

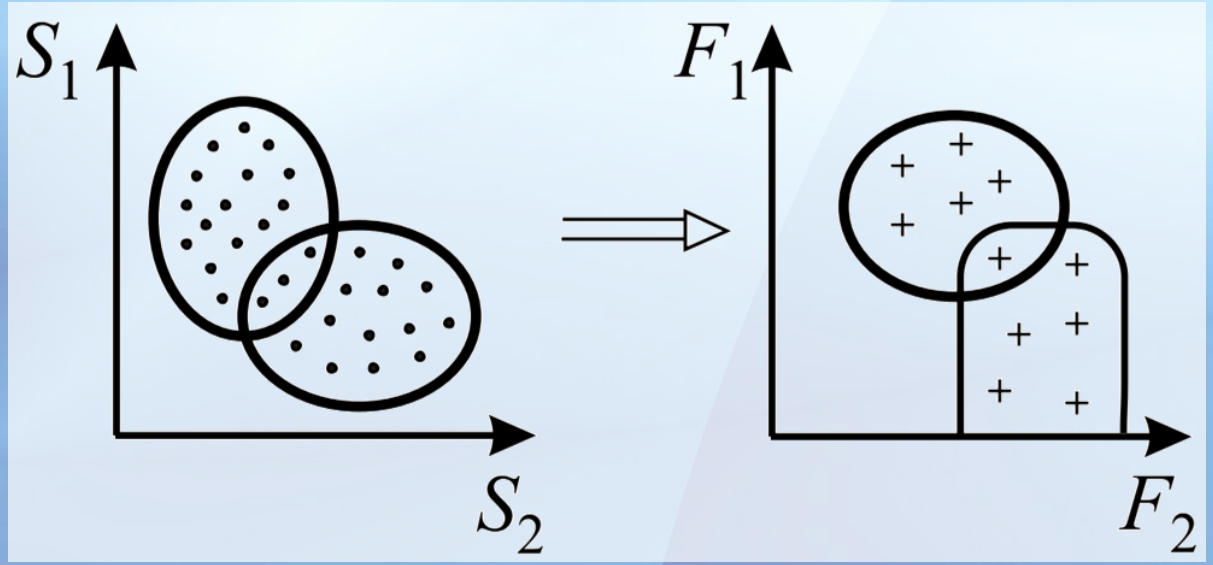
# تشخیص عیب

- روش های کلاسه بندی:
  - با توجه به اینکه نشانه ها تحلیلی یا اکتسابی می توانند برای تشخیص عیب بکار گرفته شوند، شکل واحدی مانند عدد اطمینان (Confidence number)، تابع عضویت (Membership function) مجموعه فازی و یا تابع توزیع احتمال (PDF) برای نمایش آن استفاده شود.



# روش های کلاسه بندی

- در این روش هیچ دانش اولیه ای در مورد ارتباط بین نشانه ها و نگاشت عیب وجود ندارد.

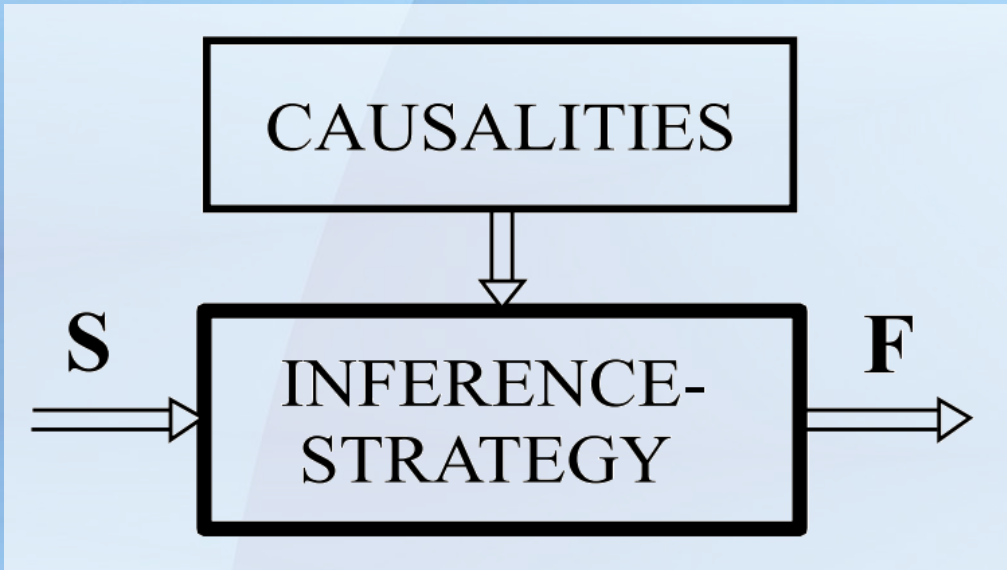



$$\mathbf{S}^T = [\, S_1, S_2 \ldots S_n \,]$$

$$\mathbf{F}^T = [\, F_1, F_2 \ldots F_m \,]$$

# تشخیص عیب

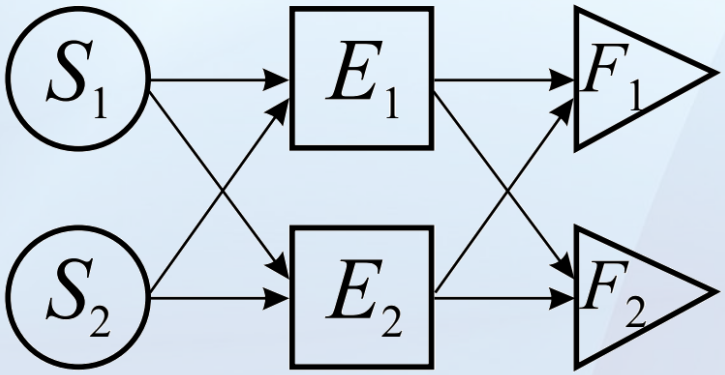
- روش های استنتاجی:
  - در صورت وجود اطلاعات بیشتر از رابطه بین نشانه ها و عیب موجود در یک سیستم می توان از روش استنتاجی استفاده کرد. مانند قوانین if-then



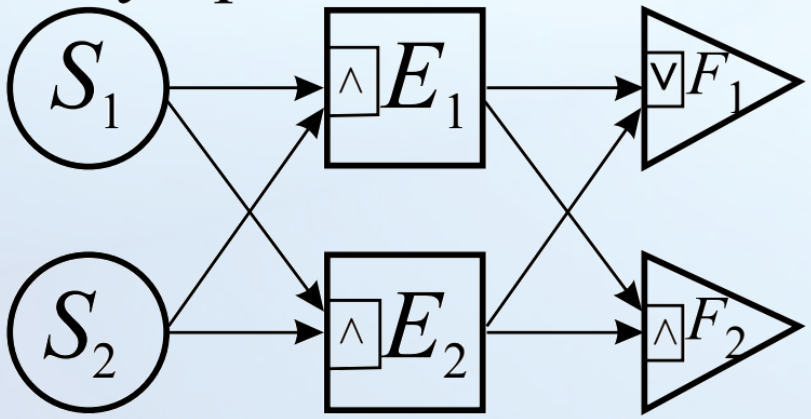
# روش های استنتاجی

- با دانش کافی از رابطه بین نشانه ها و عیب ها می توان از روش استنتاجی استفاده نمود.

Causal network:



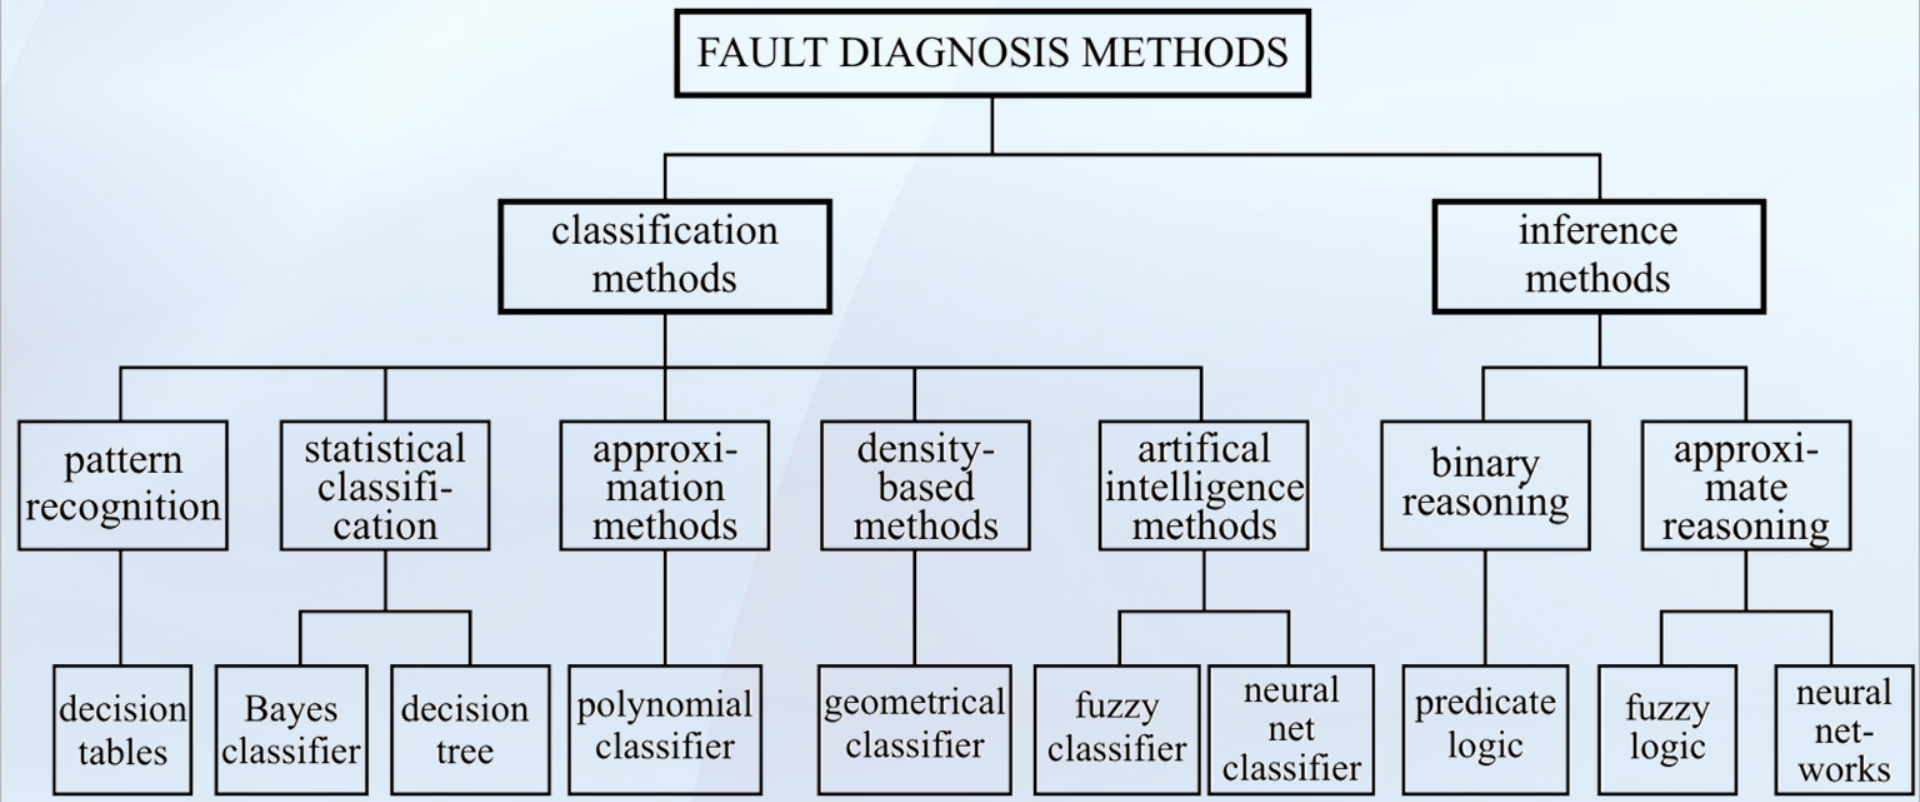

Fault-symptom tree:




IF $< S_1$ AND $S_2 >$ THEN $< E_1 >$
IF $< E_1$ OR $E_2 >$ THEN $< F_1 >$ .

# تشخیص عیب

- روشهای تشخیص عیب

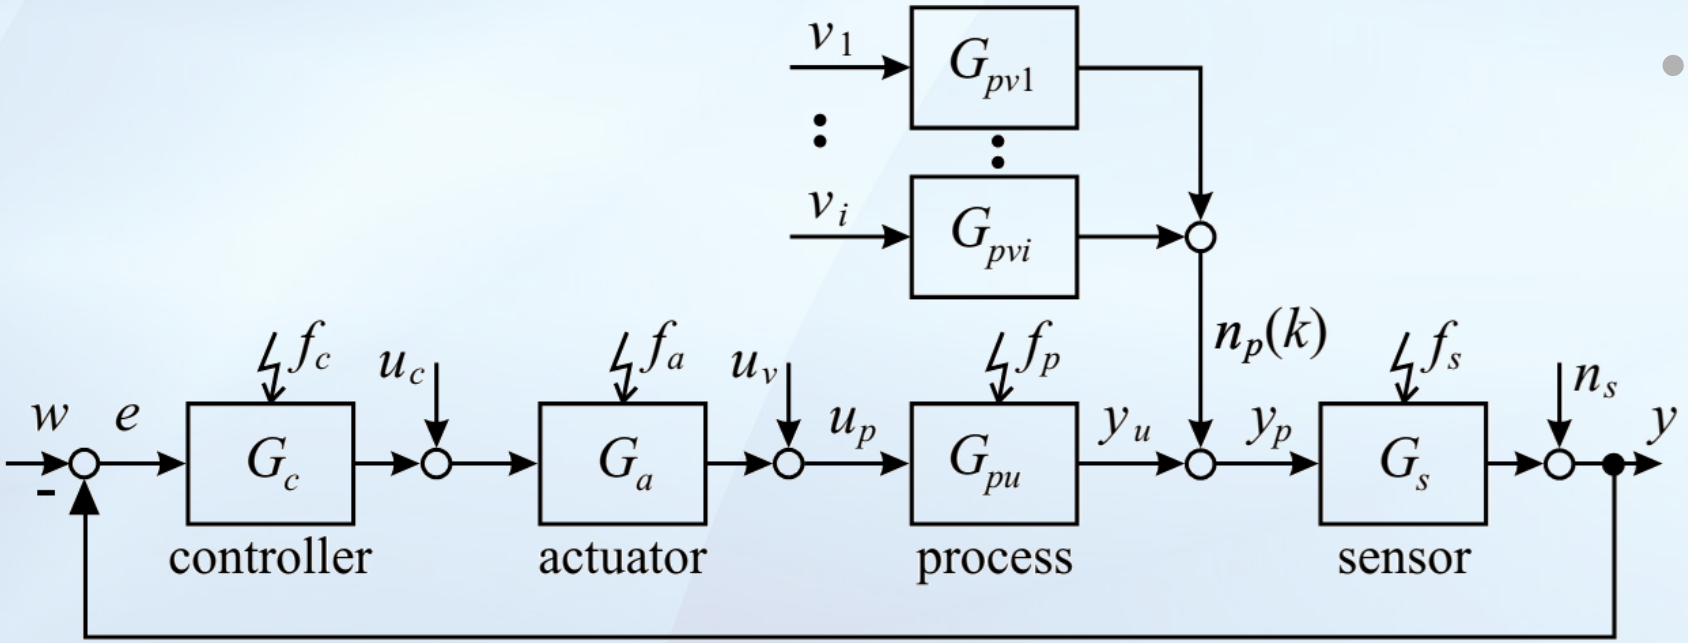


# عیب یابی در سیستم حلقه بسته

- از وظایف سیستم حلقه تعقیب مقدار مرجع با دقت بالا است.
- سیستم حلقه بسته می تواند اثر ورودی های مزاحم مانند اغتشاش، رفتار غیرخطی عملگرها و همچنین نامعینی سیستم را حذف نماید.
- با تعریف خطا:

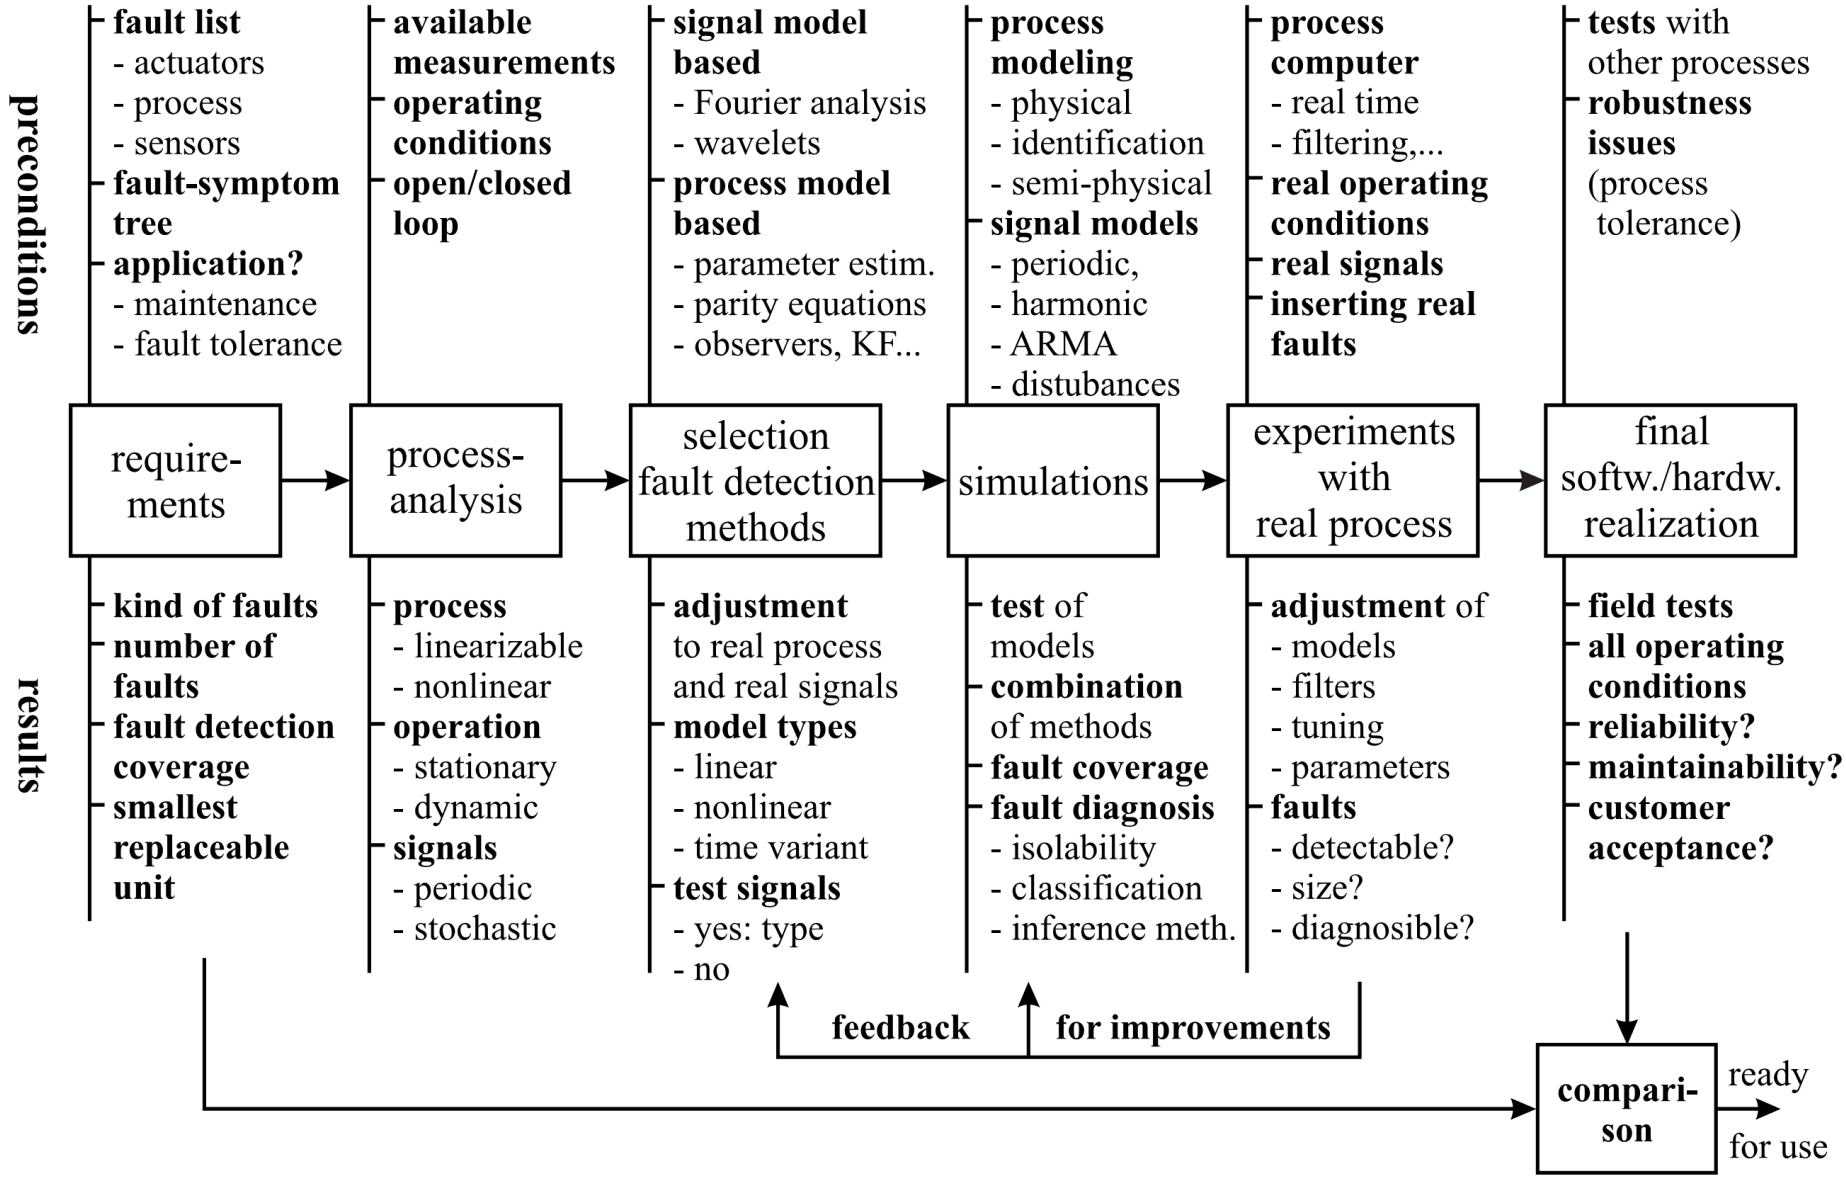
$$e(k) = w(k) - y(k)$$

# عیب یابی در سیستم حلقه بسته




| | | | |
|---|---|---|---|
| $y$ | controlled variable | $w$ | reference variable |
| $u_p$ | manipulated variable | $e$ | control deviation |
| $v_i$ | process disturbances | $n_s$ | measurement noise |
| $u_v$ | process input disturbances | $f_{c,a,p,s}$ | faults of the controller, actuator, process and sensor |
| $n_p$ | sum of process disturbances | | |
| $y_p$ | process output to be controlled | | |

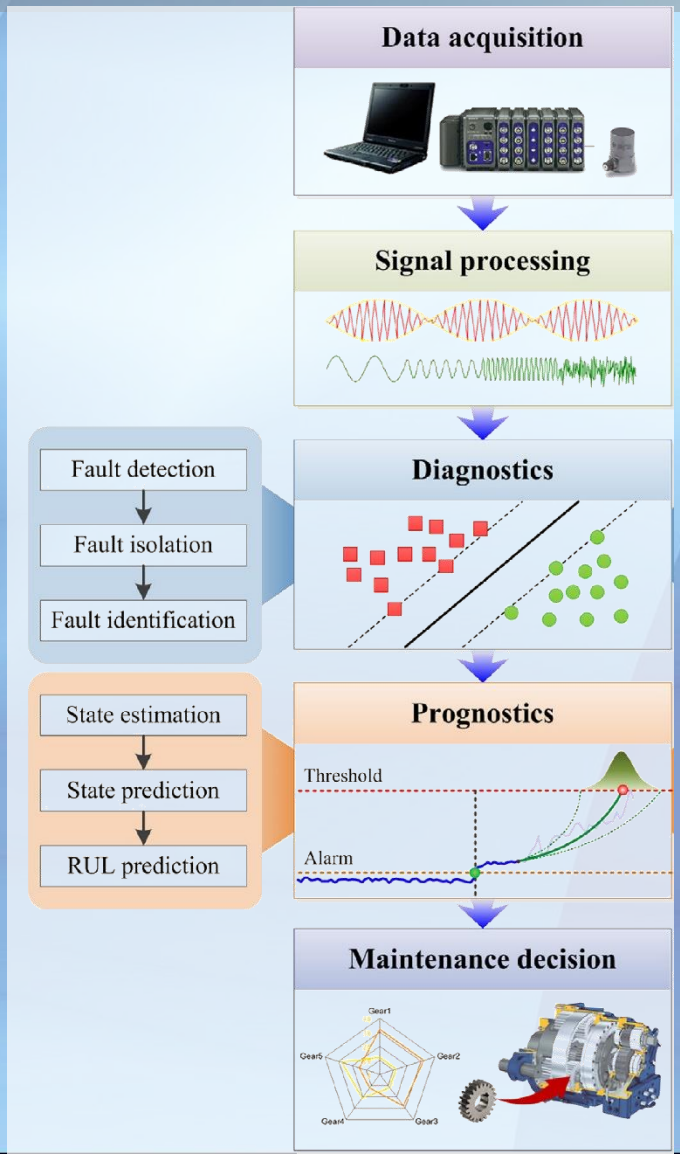
# مراحل توسعه سیستم عیب یابی



فصل چهارم

# عیب‌یابی بر پایه مدل سیگنال

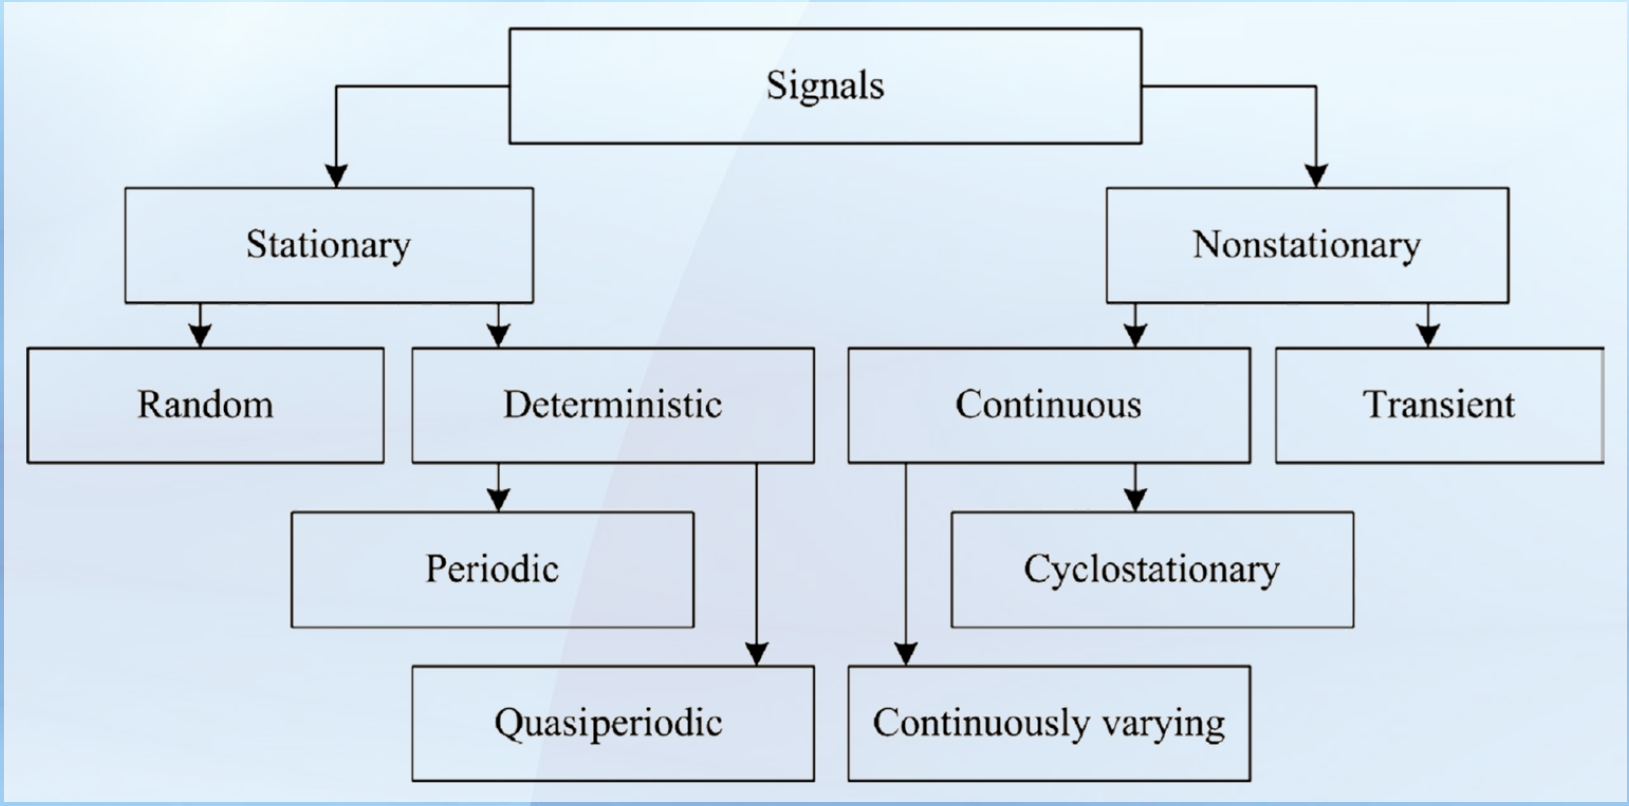
# عیب یابی بر اساس مدل سیگنال




- استفاده از مدل سیگنال در عیب یابی سیستم های صنعتی کاربرد گسترده ای دارد.
- عیب یابی بر اساس مدل سیگنال شامل چند مرحله است:
  - جمع آوری داده
  - پردازش سیگنال
  - عیب یابی
  - پیش بینی وضعیت
  - تصمیم برای تعمییرات

# مشخصات سیگنال

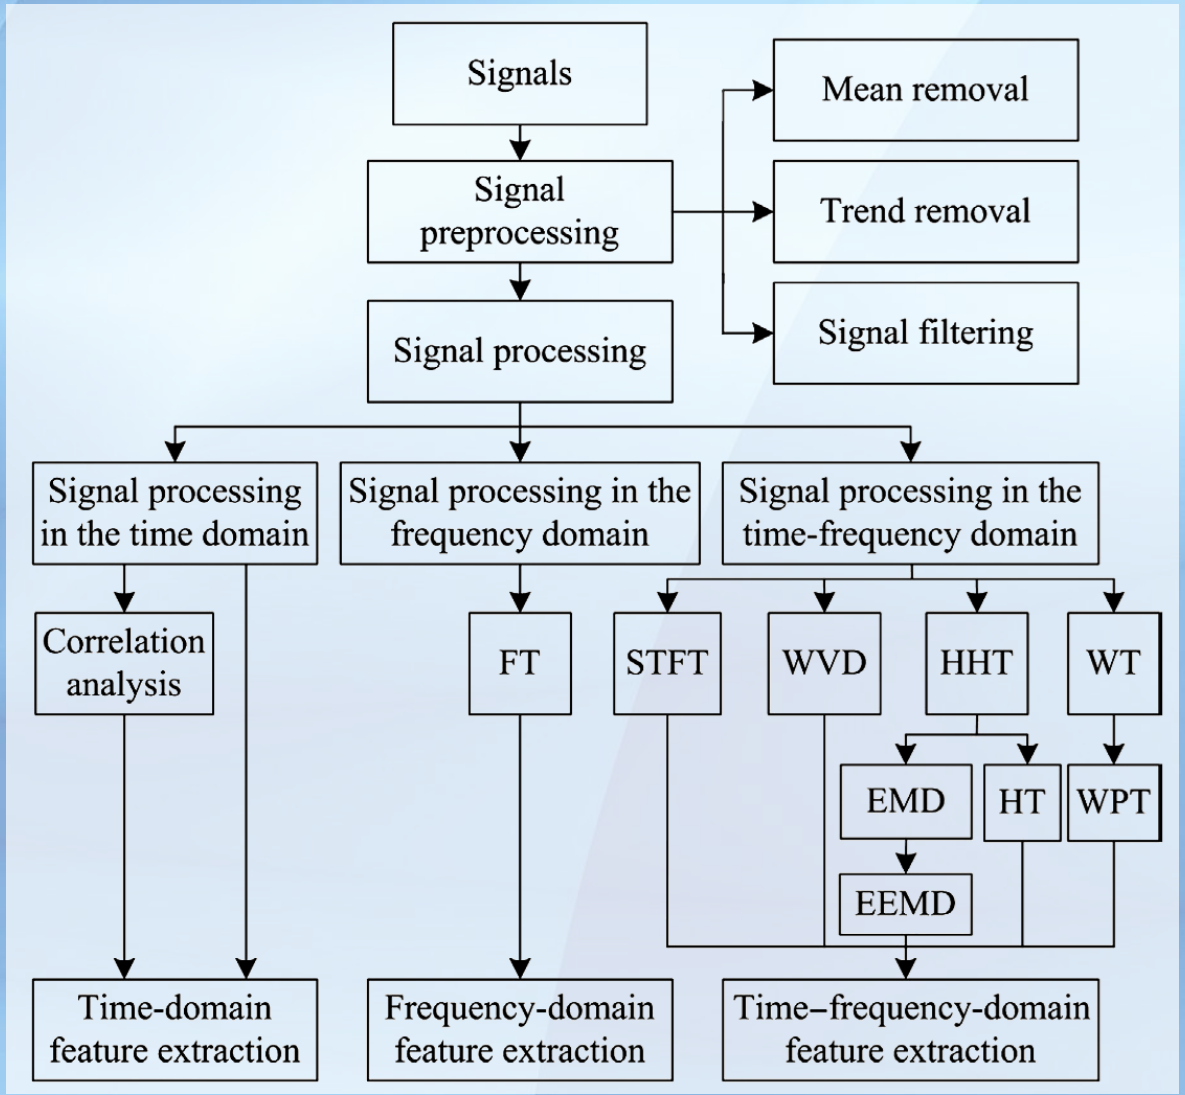
- با توجه به خواص آماری سیگنال خود، سیگنال را می توان به دسته های مختلف تقسیم کرد



# پردازش سیگنال و استخراج ویژگی

- در پردازش سیگنال اطلاعات مربوط به عیب ماشین آلات استخراج و بقایای سیگنال های بی فایده آن را از بین برده و میزان نسبت سیگنال به نویز یا SNR را افزایش می دهد.
- اهمیت پردازش سیگنال در استخراج ویژگی ها بسیار مهم است.
- روش های پردازش سیگنال:
  - حوزه زمان
  - حوزه فرکانس
  - حوزه زمان فرکانس

# پردازش سیگنال




- روش های پردازش سیگنال و استخراج ویژگی

Short-Time Fourier Transform (**STFT**)
Wigner-Ville distribution (**WVD**)
Wavelet packet transform (**WPT**)
Hilbert-Huang transform (**HHT**)

# پیش پردازش سیگنال

- بهبود کیفیت سیگنال:

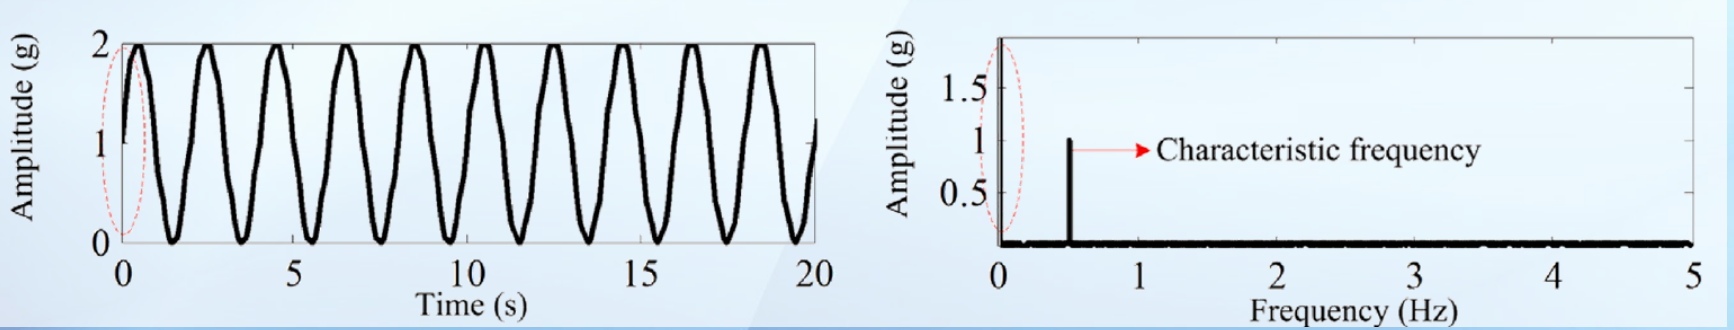
۱- حذف مقدار متوسط (mean removal)

مقدار متوسط یک سیگنال به سختی حاوی اطلاعات مفیدی درباره عیب مکانیکی یک سیستم است.

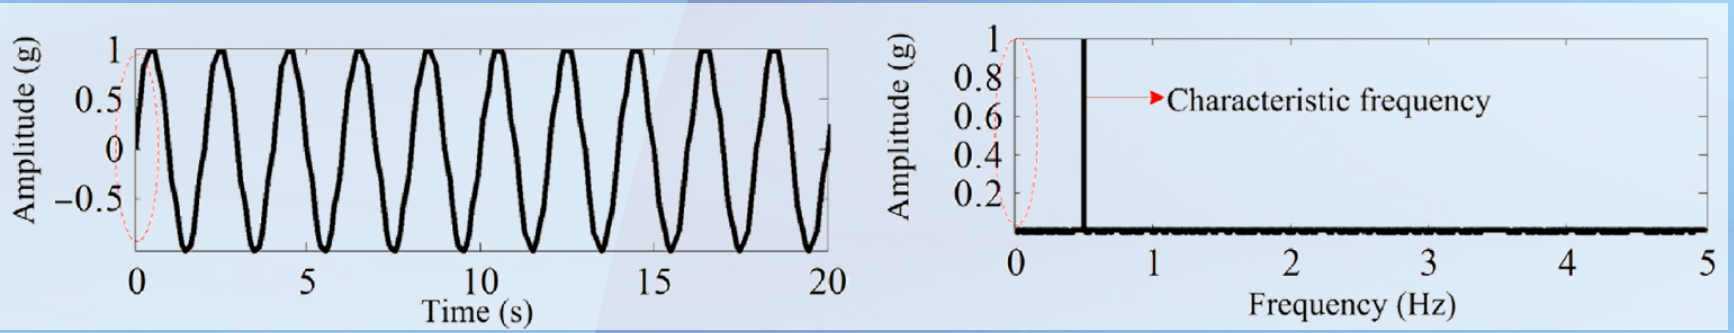
بنابراین این بخش ثابت بهتر است قبل از پردازش سیگنال حذف شود

# پیش پردازش سیگنال

- پیش از حذف مقدار متوسط




- بعد از حذف متوسط



# پیش پردازش سیگنال

- بهبود کیفیت سیگنال:

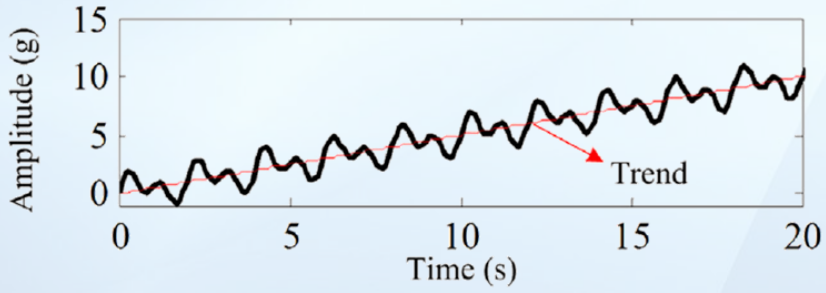
۲- حذف روند (Trend removal)

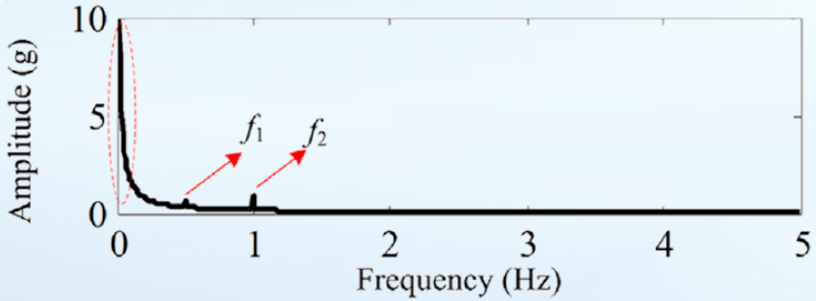
شیب تغییرات بر حسب زمان می تواند تاثیر بدی در کیفیت عیب یابی داشته باشد.

حذف روند می تواند اثر زمان را بر روی سیگنال حذف نماید.

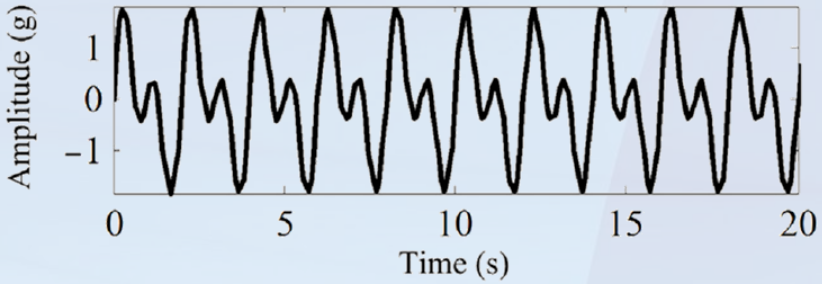
# پیش پردازش سیگنال

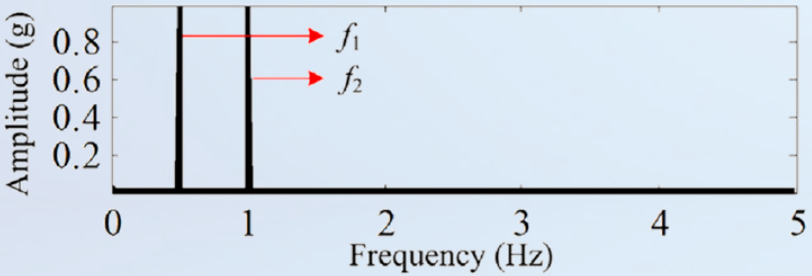
- پیش از حذف روند




- بعد از حذف روند



# پیش پردازش سیگنال

۳- فیلتر کردن سیگنال (Signal filtering)

مفهوم فیلتر کردن سیگنال بر اساس تجزیه و تحلیل سیگنال در حوزه فرکانس توسعه یافته است

- انواع فیلتر:
  - فیلترهای آنالوگ
  - فیلترهای دیجیتال
    - پاسخ ضربه نامحدود یا IIR
    - پاسخ ضربه محدود FIR

# فیلتر کردن سیگنال

- با فرض اینکه سیگنال محتوی نویز است: $x(t) = s(t) + n(t)$
- در صورتی که سیگنال فیلتر شده: $y(t)$
- تابع تبدیل فیلتر به شکل زیر است

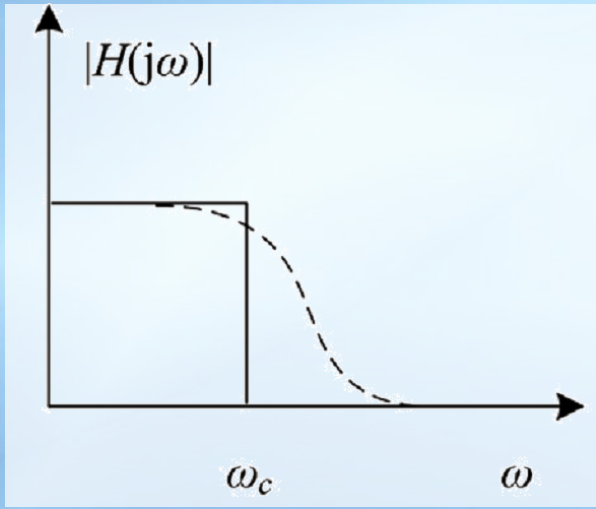
$$H(\omega)=Y(\omega)/X(\omega)$$

$Y(\omega)$ and $X(\omega)$ represent FT of the signals $y(t)$ and $x(t)$

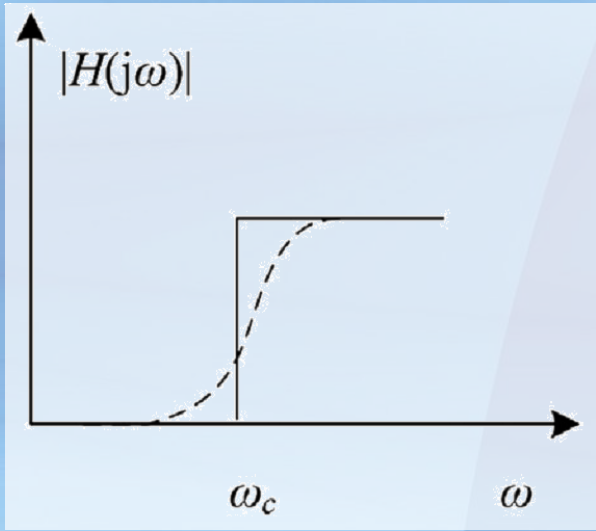
$$\begin{cases} H(\omega)=1, & S(\omega)\neq 0 \\ H(\omega)=0, & S(\omega)=0 \end{cases}$$

$S(\omega)$ is the FT of useful component $s(t)$

# فیلتر کردن سیگنال

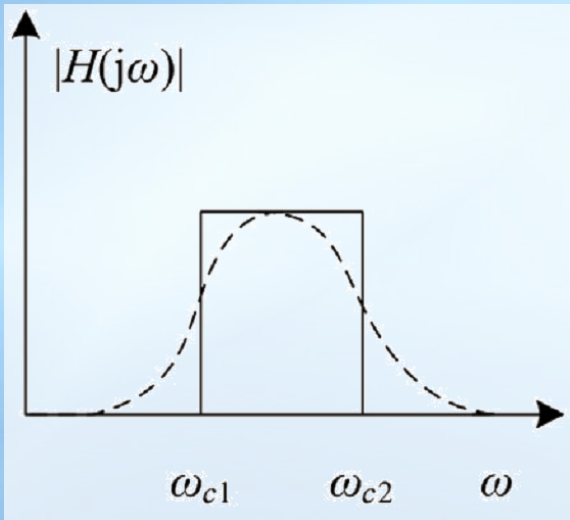



- فیلتر پایین گذر
- Low-pass filter

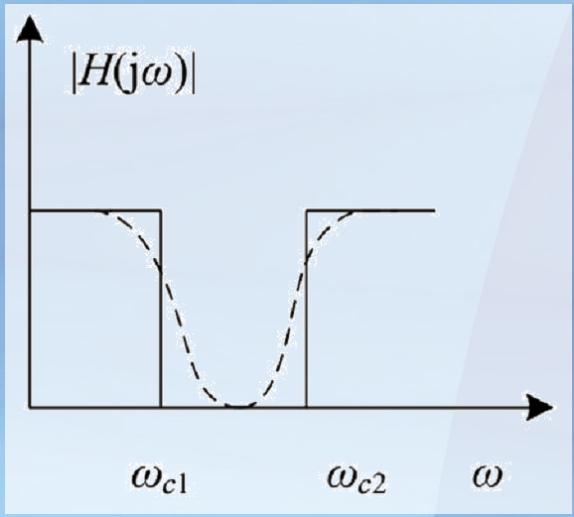



- فیلتر بالا گذر
- High-pass filter

# فیلتر کردن سیگنال



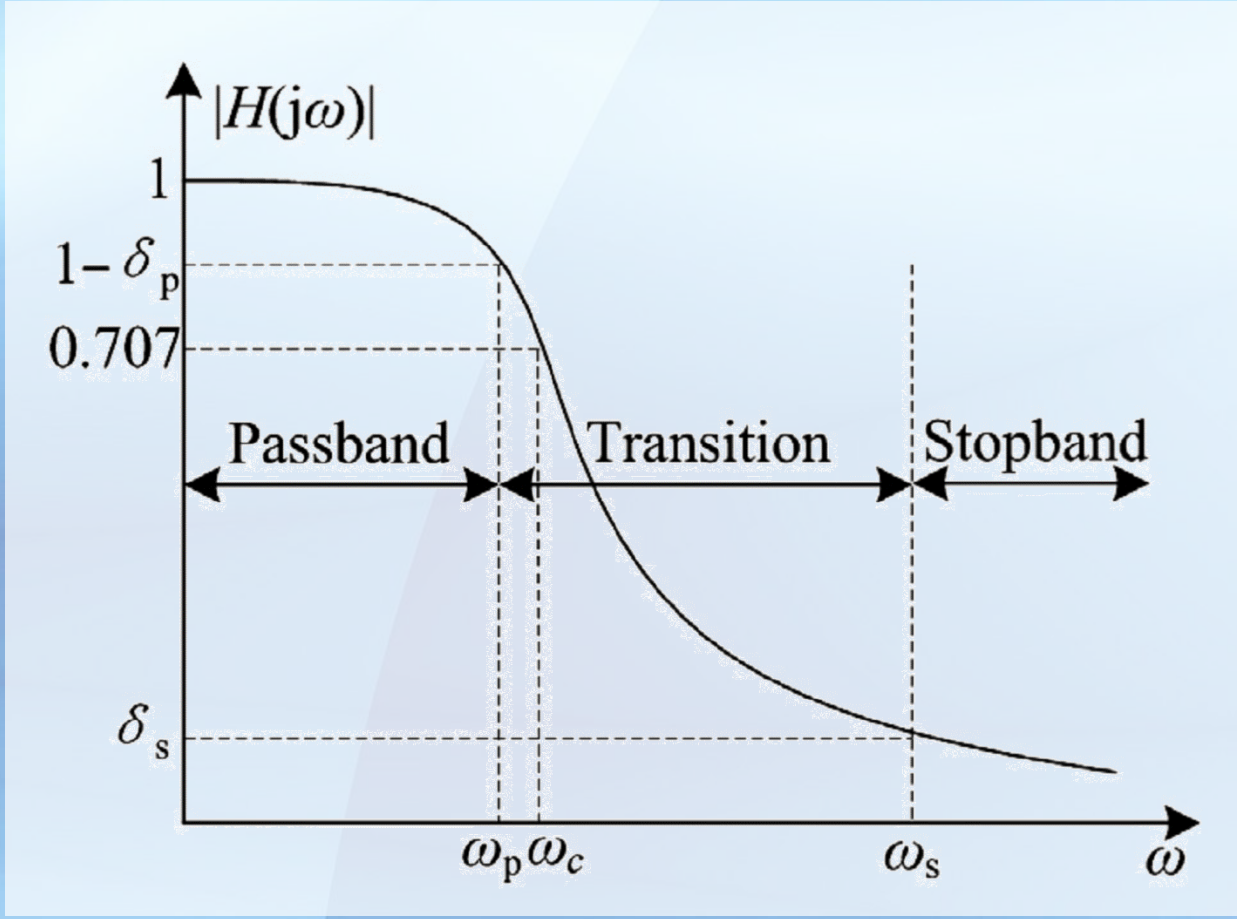

- فیلتر باند گذر
- Band-pass filter




- فیلتر باند توقف
- Band-stop filter

# فیلتر کردن سیگنال

- مشخصات یک فیلتر آنالوگ پایین گذر به شکل زیر است



# فیلتر کردن سیگنال

- فیلترهای دیجیتال نیز در حالت کلی می توانند به ۲ شکل زیر باشند:

IIR –

$$H(z)=\frac{\sum_{r=0}^{M} b_r z^{-r}}{1+\sum_{k=1}^{N} a_k z^{-k}}$$

$$z=\exp(j\omega\Delta t),\ a_k(k=1,2,\cdots,N)\ \text{and}\ b_r(r=0,1,2,\cdots,M)$$

FIR –

$$H(z)=\sum_{n=0}^{N-1} h(n) z^{-n}$$

$$h(n)\ (n=0,1,2,\cdots,N-1)$$

# پردازش سیگنال در حوزه زمان

- پردازش سیگنال در حوزه زمان شامل دو روش زیر می باشد:
  - آنالیز همبستگی (Correlation Analysis)
  - استخراج ویژگی آماری (Statistical Feature Extraction)

# آنالیز همبستگی

- آنالیز همبستگی نشان دهنده رابطه متقابل بین دو سیگنال است.
- به طور کلی، رابطه می تواند به عنوان ضرب درونی بین دو سیگنال نوشته شود.

$$\langle x,y\rangle = \int_0^T x(t)y(t)dt$$

که در آن T زمان مشاهده دو سیگنال y و x است. در صورت وجود مشابهت زیاد مقدار ضرب داخلی بزرگ می شود.

# آنالیز همبستگی

- خودهمبستگی (Autocorrelation) یک سیگنال به صورت زیر است:

$$R_x(\tau) = \lim_{T\to\infty} \frac{1}{T} \int_0^T x(t)x(t+\tau)dt$$

$$\rho_x(\tau) = \frac{R_x(\tau)}{\sigma_x^2}$$

- تابع $R_x(\tau)$ یک تابع حقیقی است
- تابع $R_x(\tau)$ یک تابع زوج است $R_x(\tau) = R_x(-\tau)$
- تابع $R_x(0)$ حداقل مربعات سیگنال x است.

# آنالیز همبستگی

- همبستگی متقابل دو سیگنال x و y به صورت زیر است

$$R_{xy}(\tau)=\lim_{T\to\infty}\frac{1}{T}\int_0^T x(t)y(t+\tau)dt$$

- کوواریانس

$$C_{xy}(\tau)=\lim_{T\to\infty}\frac{1}{T}\int_0^T\left\{\left[x(t)-\mu_x\right]\left[y(t+\tau)-\mu_y\right]\right\}$$

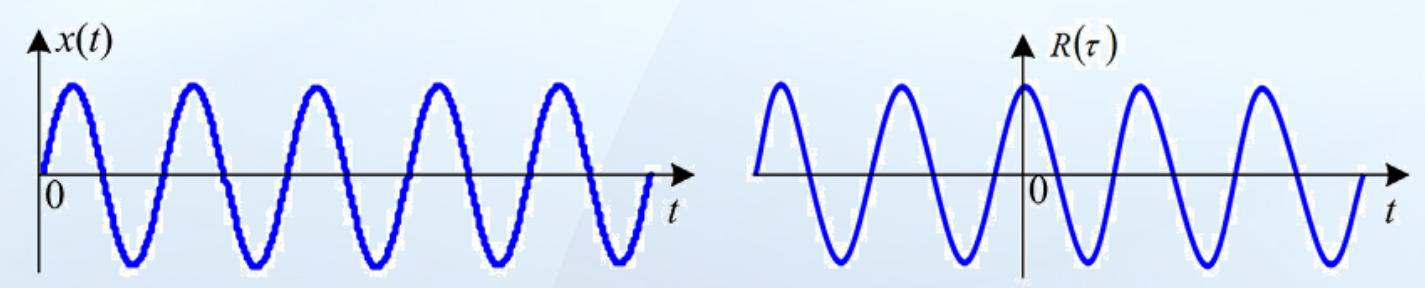
- ضریب همبستگی

$$\rho_{xy}(\tau)=\frac{C_{xy}(\tau)}{\sigma_x\sigma_y}$$

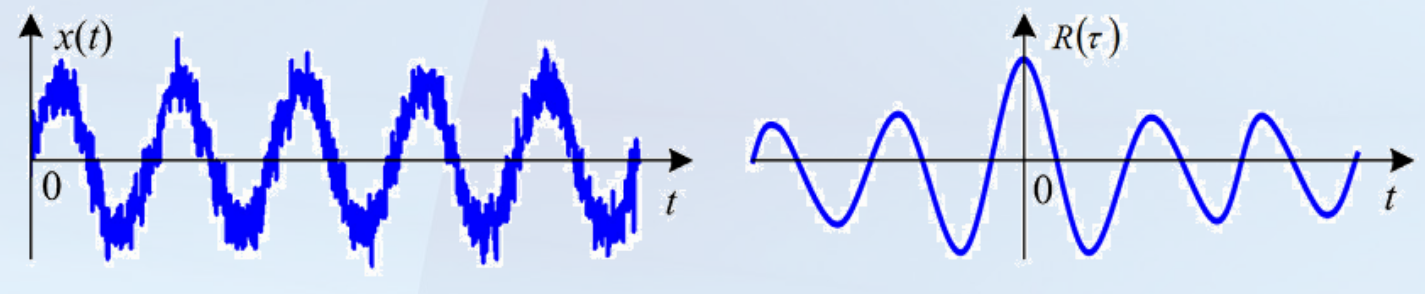
# آنالیز همبستگی

- تابع خودهمبستگی سیگنال های مختلف به شکل زیر است:

- periodic signal

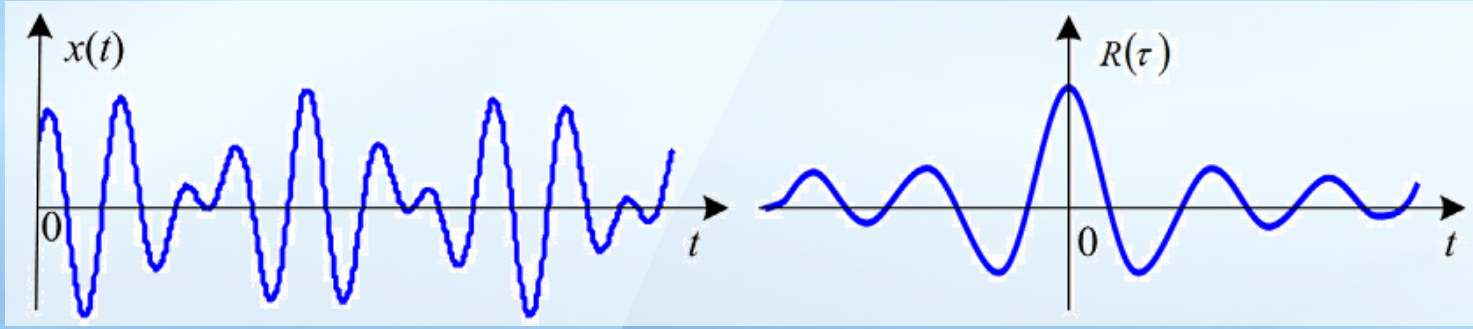



- periodic signal with noise

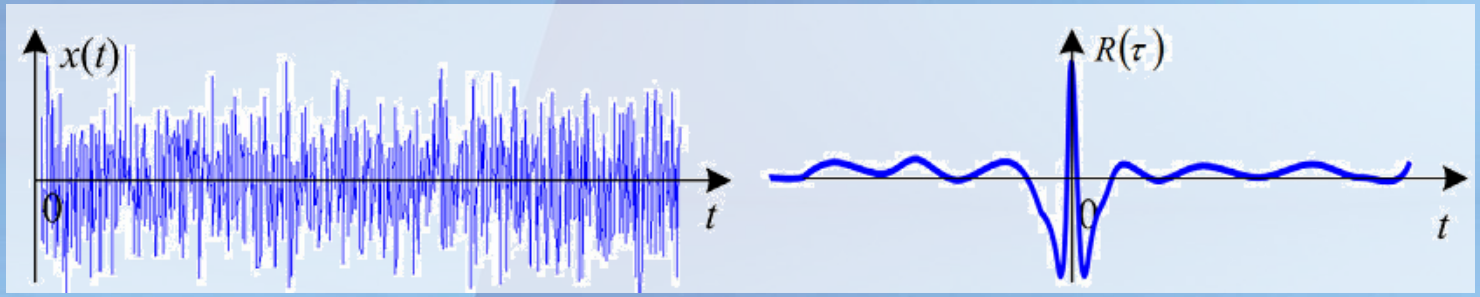


# آنالیز همبستگی

- narrow-band noise




- broad-band noise



# استخراج ویژگی آماری حوزه زمان

- هنگام رخداد یک عیب، سختی سازه های مکانیکی اطراف عیب باید تغییر کند که این می تواند سبب ایجاد یک ضربه یا شوک شود.
- این ضربه همچنین ممکن است سبب تغییر در سیگنال های ارتعاشی شود. لذا دامنه و توزیع این سیگنالها در حوزه زمانی تغییر می کند.
- بنابراین، می توان ویژگی های آماری را از شکل موج ها در حوزه زمانی استخراج نمود که هر یک منعکس کننده یک عیب مکانیکی باشد.

# استخراج ویژگی آماری حوزه زمان

- معروف ترین ویژگی های حوزه زمانی به شرح ذیل هستند:

- $X_m$ : Mean value

$$X_m = \frac{\sum_{n=1}^{N} x(n)}{N}$$

- $X_{root}$ : Root amplitude

$$X_{root} = \left( \frac{\sum_{n=1}^{N} \sqrt{|x(n)|}}{N} \right)^2$$

- $X_{rms}$ : Root mean square

$$X_{rms} = \sqrt{\frac{\sum_{n=1}^{N} (x(n))^2}{N}}$$

# استخراج ویژگی آماری حوزه زمان

- $X_{peak}$ : Peak amplitude

$$X_{peak} = \max|x(n)|$$

- $X_{Skewness}$ : Skewness

$$X_{skewness} = \frac{\sum_{n=1}^{N}\left(x(n) - X_m\right)^3}{(N-1)X_{sd}^3}$$

- $X_{Kurtosis}$ : Kurtosis value

$$X_{kurtosis} = \frac{\sum_{n=1}^{N}\left(x(n) - X_m\right)^4}{(N-1)X_{sd}^4}$$

# استخراج ویژگی آماری حوزه زمان

- $X_{crest}$ : Crest factor

$$X_{crest} = \frac{X_{peak}}{X_{rms}}$$

- $X_{clearance}$ : Clearance factor

$$X_{clearance} = \frac{X_{peak}}{X_{root}}$$

- $X_{shape}$ : Shape factor

$$X_{shape} = \frac{X_{rms}}{\frac{1}{N}\sum_{n=1}^{N}|x(n)|}$$

# استخراج ویژگی آماری حوزه زمان

- $X_{impulse}$ : Impulse factor

$$X_{impulse} = \frac{X_{peak}}{\frac{1}{N}\sum_{n=1}^{N}|x(n)|}$$

- با توجه به درجه عیب ایجاد شده، هر یک از این ویژگی ها نشانگر بخشی از اطلاعات عیب بوده به صورتی که بعضی از آنها ممکن است نتوانند مشخصات عیب را به خوبی نشان دهند.
- بنابراین ویژگی مناسب باید متناسب با عیب مورد نظر انتخاب شود.

# پردازش سیگنال در حوزه فرکانسی

- پردازش سیگنال در حوزه فرکانس می تواند مشکل پردازش سیگنال در حوزه زمانی که تنها تغییرات شکل موج سیگنال را نشان داده اما ماهیت ذاتی سیگنال را بیان نمی کند، را جبران کند.
- تجزیه و تحلیل طیف فرکانسی مبنای تجزیه و تحلیل سیگنال در حوزه فرکانس است.
- تئوری اصلی آن Fourier Transform است.

# پردازش سیگنال در حوزه فرکانسی

- تحلیل فوریه اساسی ترین روش تحلیل در حوزه فرکانسی است.
  - سری فوریه
  - انتگرال فوریه
  - تبدیل فوریه گسسته یا DFT
  - تبدیل فوریه سریع یا FFT

# سری فوریه

- مفهوم اصلی FT تجزیه یک سیگنال به صورت جمع جملات سینوسی و کوسینوسی است

$$x(t)=x(t+nT)$$

$$x(t)=\frac{a_0}{2}+\sum_{k=1}^{\infty}a_k\cos(k\omega_0 t)+\sum_{k=1}^{\infty}b_k\sin(k\omega_0 t)$$

$$a_k=\frac{2}{T}\int_{-T/2}^{T/2}x(t)\cos(k\omega_0 t)dt$$

$$b_k=\frac{2}{T}\int_{-T/2}^{T/2}x(t)\sin(k\omega_0 t)dt$$

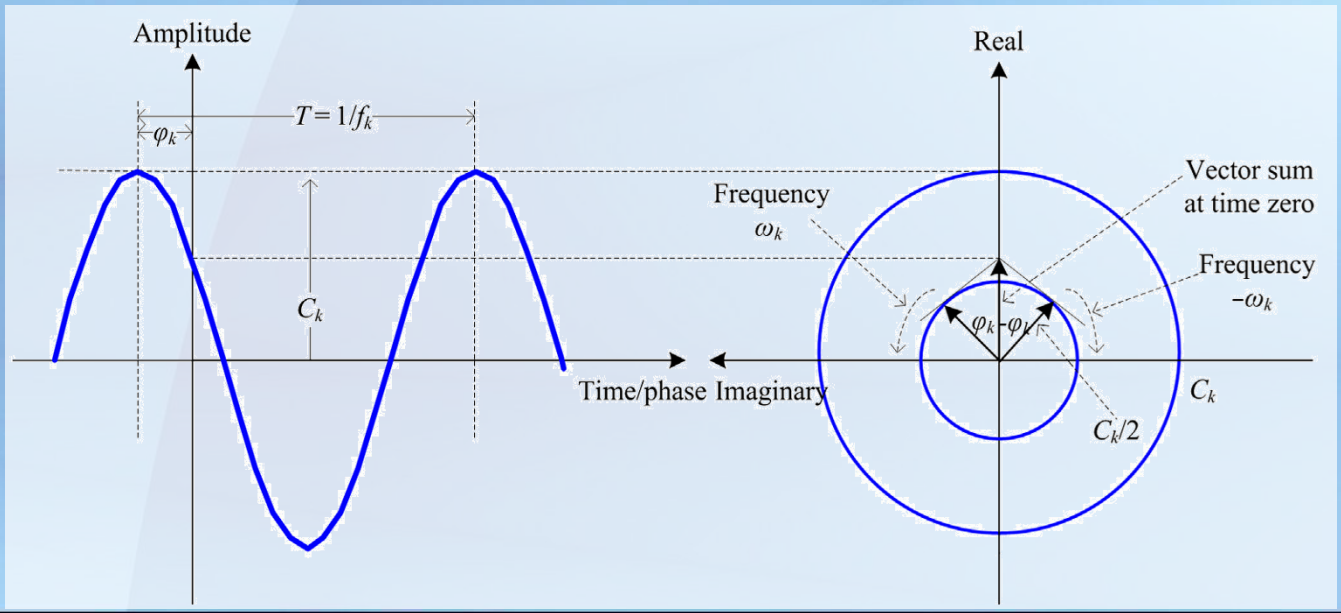
# سری فوریه

$$a_k \cos(\omega_k t) + b_k \sin(\omega_k t)$$

$$C_k \cos(\omega_k t + \varphi_k)$$

$$C_k = \sqrt{a_k^2 + b_k^2} \quad \text{and} \quad \varphi_k = \tan^{-1}(b_k / a_k)$$

- سری فوریه می توان به صورت یک دامنه و فاز تبدیل شود:



# سری فوریه مختلط

- بر اساس وجود دامنه و فاز سیگنال، می توان سری فوریه را به شکل سری فوریه مختلط به شکل زیر تبدیل نمود.

$$x(t)=\sum_{k=-\infty}^{\infty} A_k \exp(j\omega_k t)$$

$$A_k=\frac{1}{T}\int_{-T/2}^{T/2} x(t)\exp(-j\omega_k t)dt$$

# تبدیل فوریه

- سیگنال متناوب به ویژه برای گذرا می توانید به صورت انتگرال نمایی به شکل زیر تجزیه شود.

$$X(f)=\int_{-\infty}^{\infty} x(t)\exp(-\mathrm{j}2\pi ft)dt$$

$$x(t)=\int_{-\infty}^{\infty} X(f)\exp(\mathrm{j}2\pi ft)df$$

# سری فوریه گسسته

- در صورت وجود داده های نمونه برداری شده، می توان تبدیل فوریه را به شکل گسسته آن نیز تبدیل نمود. در این صورت تبدیل فوریه گسسته و طبیعتا معکوس آن به فرم زیر قابل ارائه است.

$$X(f)=\sum_{n=-\infty}^{\infty} x(t_n)\exp(-\mathrm{j}2\pi f t_n)$$

$$x(t_n)=\frac{1}{f_s}\int_{-f_s/2}^{f_s/2} X(f)\exp(\mathrm{j}2\pi f t_n)\,df$$

$$t_n = n\Delta t = n/f_s,$$

# سری فوریه گسسته

- سری فوریه گسسته به صورت جمع متناهی به شکل زیر قابل تعریف است:

$$X(k)=\frac{1}{N}\sum_{n=0}^{N-1}x(n)\exp\left(\frac{-\mathrm{j}2\pi kn}{N}\right)$$

$$x(n)=\sum_{k=0}^{N-1}X(k)\exp\left(\frac{\mathrm{j}2\pi kn}{N}\right)$$

- شامل $N^2$ جمله ضربی مختلط و $N(N-1)$ جمله جمع مختلط خواهد بود.

# سری فوریه گسسته

- سری فوریه گسسته را می توان به صورت ماتریس ضربی نیز ارائه نمود که در آن Xk بردار N عضو فرکانسی است.

$$\mathbf{X}_k = \frac{1}{N}\mathbf{M}_{kn}\mathbf{x}_n$$

# تبدیل فوریه سریع

- The Fast Fourier transform (FFT)
- نوشتن برنامه ای که بتواند مقدار تبدیل فوریه گسسته را محاسبه نماید بسیار ساده ولی با این حال بسیار کند است.
- برای انجام سریع تر محاسبه آن الگوریتم های متفاوتی ارائه شده است.

• Gauss, 1805 • Gooley & Tukey, 1965

# تبدیل فوریه سریع

- با در نظر گرفتن

$$W_N = \exp(-j\,2\pi / N)$$

- استفاده از متقارن بودن و متناوب بودن تابع نمایی می تواند حجم محاسبه را کاهش دهد.

– symmetry: $W_N^{k[N-n]} = W_N^{-kn} = (W_N^{kn})^*$

– Periodicity $W_N^{kn} = W_N^{k[n+N]} = W_N^{[k+N]n}$

– توجه اینکه:

$$W_N^{KN} = \exp(-j\,2\pi KN\ / N) = 1$$

# تبدیل فوریه سریع

- با تفکیک جملات فرد و زوج سری فوریه گسسته خواهیم داشت:

$$X[k] = \sum_{n=0}^{N-1} x[n] W_N^{nk}$$

$$= \sum_{n\ even} x[n] W_N^{nk} + \sum_{n\ odd} x[n] W_N^{nk}$$

$$= \sum_{r=0}^{\frac{N}{2}-1} x[2r] (W_N^2)^{rk} + W_N^k \sum_{r=0}^{\frac{N}{2}-1} x[2r+1] (W_N^2)^{rk}$$

$$= \sum_{r=0}^{\frac{N}{2}-1} x[2r] W_{N/2}^{rk} + W_N^k \sum_{r=0}^{\frac{N}{2}-1} x[2r+1] W_{N/2}^{rk}$$

# تبدیل فوریه سریع

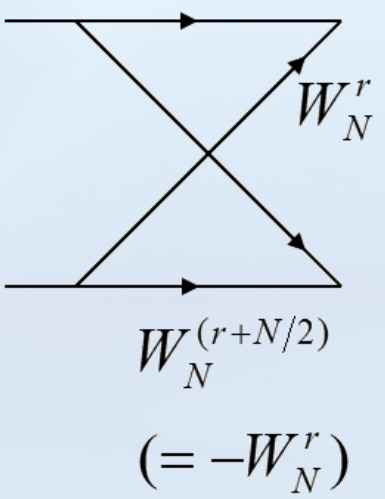
- نتیجه جمع دو DFT با طول N/2 است.

$$X[k] = \underbrace{G[k]}_{\substack{\text{N/2 DFT} \\ \text{of even samples}}} + W_N^k \cdot \underbrace{H[k]}_{\substack{\text{N/2 DFT} \\ \text{of odd samples}}}$$

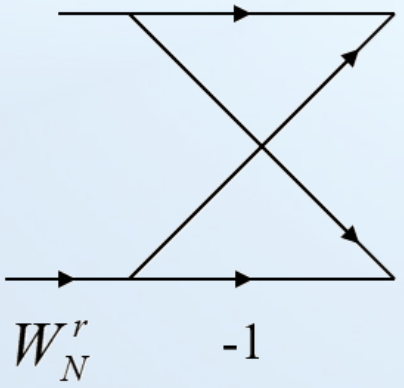
- Two N/2-point DFTs
  - $2(N/2)^2$ complex multiplications
  - $2(N/2)^2$ complex additions

# تبدیل فوریه سریع

- برای محاسبه G[k] و H[k] در دیاگرام جریانی از روش پروانه یا "butterfly" استفاده می شود.

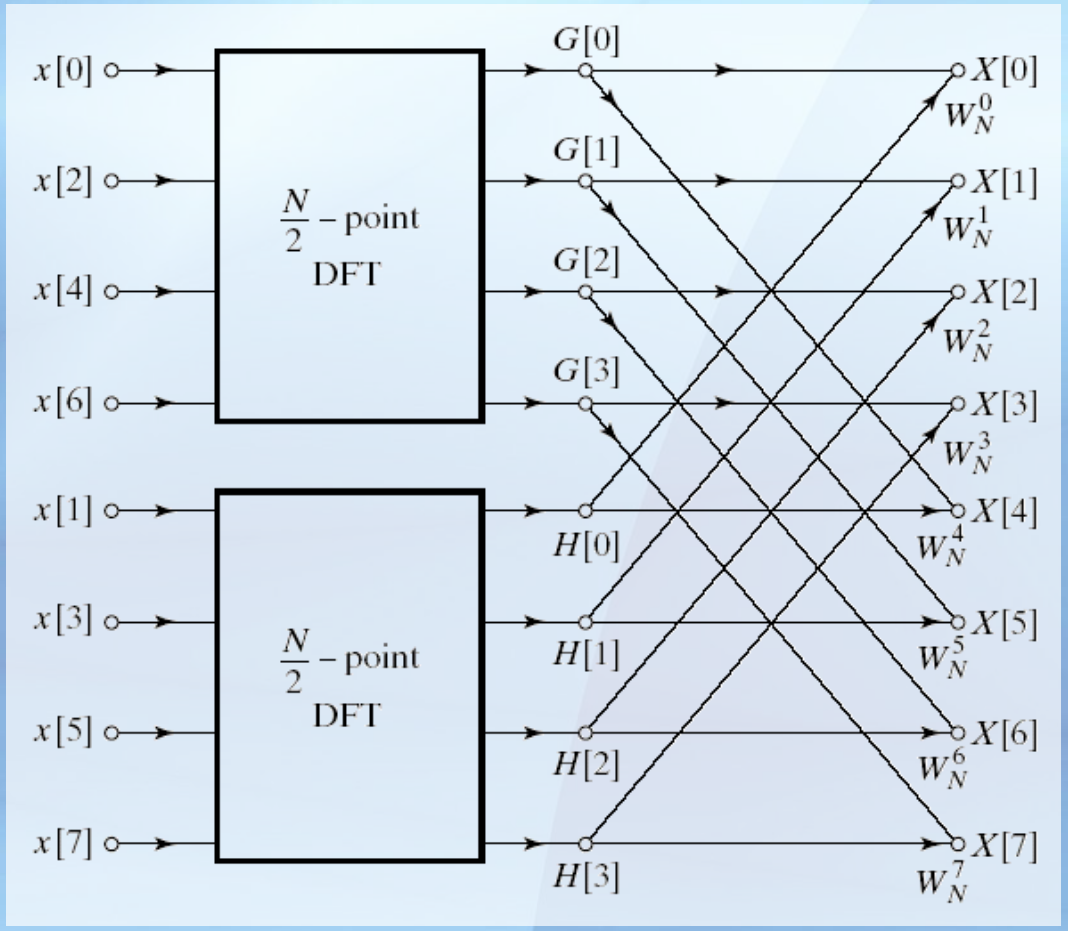



or simplify:



# تبدیل فوریه سریع

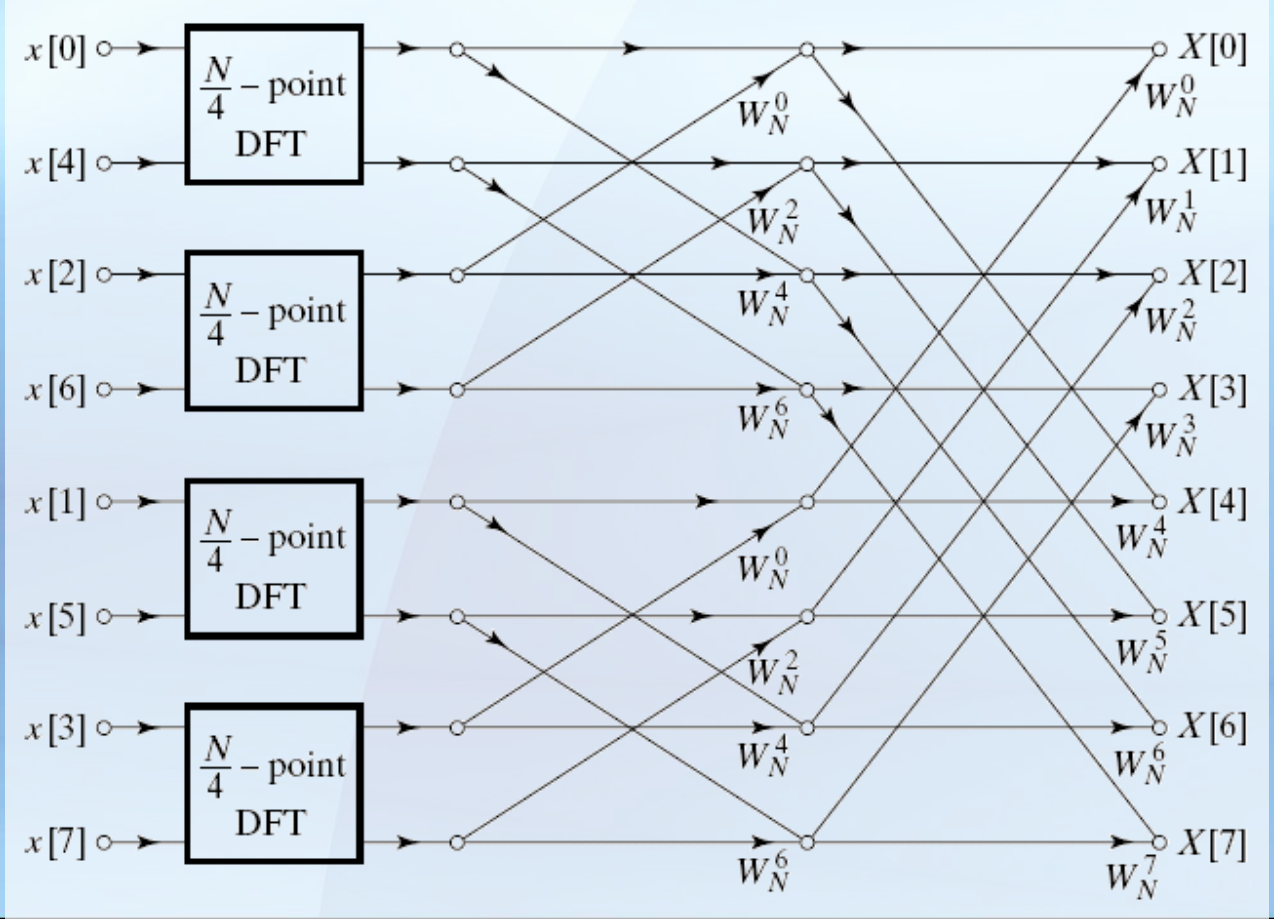
- حاصل DFT با طول N/2 به شکل زیر خواهد بود.




- N complex multiplications
- N complex additions

# تبدیل فوریه سریع

- مجددا N/2-point DFTs به دو N/4-point DFTs تقسیم و با هم ترکیب می شود



# تبدیل فوریه سریع

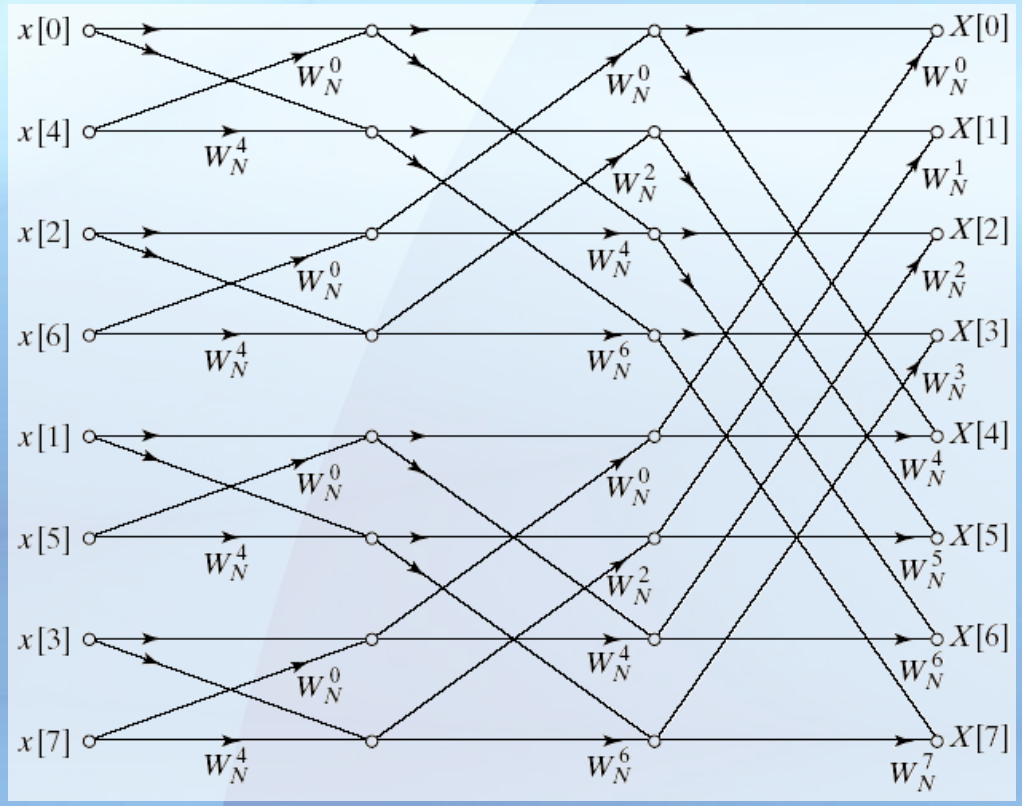
- این روش نیازمند ثبت اطلاعات ورود و خروجی هر لایه در حافظه است.
- یک روش استفاده از ایندکس رزرو حافظه است

$$X_0[0] = x[0] \leftrightarrow X_0[000] = x[000]$$
$$X_0[1] = x[4] \leftrightarrow X_0[001] = x[100]$$
$$X_0[2] = x[2] \leftrightarrow X_0[010] = x[010]$$
$$X_0[3] = x[6] \leftrightarrow X_0[011] = x[110]$$
$$X_0[4] = x[1] \leftrightarrow X_0[100] = x[001]$$
$$X_0[5] = x[5] \leftrightarrow X_0[101] = x[101]$$
$$X_0[6] = x[3] \leftrightarrow X_0[110] = x[011]$$
$$X_0[7] = x[7] \leftrightarrow X_0[111] = x[111]$$

# تبدیل فوریه سریع

- شکل FFT برای تقسیم N/8 :

$$N = 8 = 2^3 \quad (P = 3)$$




Complexity:

- $N\log_2 N$ complex multiplications and additions

# تبدیل فوریه سریع

- با ادامه دادن تقسیم ها ، می توان مقدار دقت به ازای N تقسیم:

$$1: \mathrm{N}/2 \rightarrow 2(\mathrm{N}/2)^2 + N$$

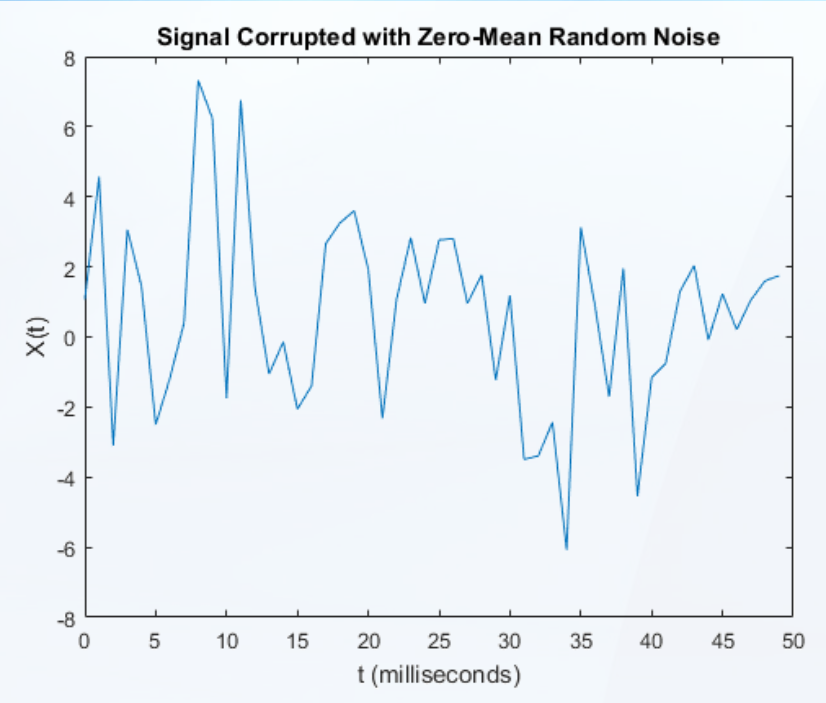
$$2: \mathrm{N}/4 \rightarrow 2(2(\mathrm{N}/4)^2 + N/2) + N = \mathrm{N}^2/4 + 2N$$

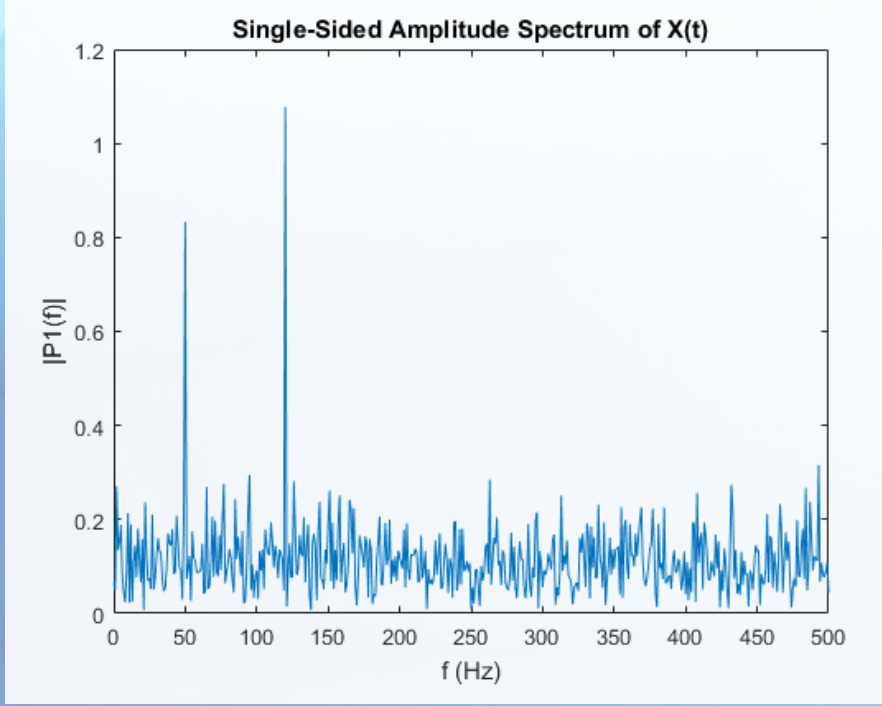
$$3: \mathrm{N}/8 \rightarrow 2(2(2(\mathrm{N}/8)^2 + N/4)) + N = \mathrm{N}^2/8 + 3N$$

$$4: \mathrm{N}/2^P = 1 \rightarrow \mathrm{N}^2/2^P + P^N = O(N \log_2 N)$$

# تبدیل فوریه سریع

- نمونه ای از تبدیل فوریه سریع یک سیگنال نویزی توسط دستور fft در متلب:




- طیف فرکانسی در دو نقطه بزرگتر است.

# استخراج ویژگی آماری در حوزه فرکانس

در هنگام بروز عیب در یک ماشین، برخی از فرکانس های غیرطبیعی در طیف فرکانس سیگنال های ارتعاش ظاهر می شوند که می توانند نشان دهنده شرایط سلامتی ماشین باشند.

طیف فرکانس به عیب های آغازین حساس تر هستند، زیرا تغییرات نامطلوب را به صورت خط طیف در فرکانس متفاوتی از طیف های فرکانسی سیستم سالم ایجاد می کنند.

برای استخراج ویژگی در حوزه فرکانسی، توابع متفاوتی وجود دارد

# ویژگی آماری در حوزه فرکانس

$$p_1 = X_{mf} = \frac{\sum_{k=1}^{K} s(k)}{K}$$

$$p_2 = \frac{\sum_{k=1}^{K} \left(s(k) - p_1\right)^2}{K-1}$$

$$p_3 = \frac{\sum_{k=1}^{K} \left(s(k) - p_1\right)^3}{K\left(\sqrt{p_2}\right)^3}$$

$$p_4 = \frac{\sum_{k=1}^{K} \left(\left(s(k) - p_1\right)\right)^4}{Kp_2^2}$$

$$p_5 = X_{fc} = \frac{\sum_{k=1}^{K} f_k s(k)}{\sum_{k=1}^{K} s(k)}$$

$$p_6 = \sqrt{\frac{\sum_{k=1}^{K} \left(f_k - P_5\right)^2 s(k)}{K}}$$

$$p_7 = X_{rmsf} = \sqrt{\frac{\sum_{k=1}^{K} f_k^2 s(k)}{\sum_{k=1}^{K} s(k)}}$$

$$p_8 = \sqrt{\frac{\sum_{k=1}^{K} f_k^4 s(k)}{\sum_{k=1}^{K} f_k^2 s(k)}}$$

$$p_9 = \frac{\sum_{k=1}^{K} f_k^2 s(k)}{\sqrt{\sum_{k=1}^{K} s(k) \sum_{k=1}^{K} f_k^4 s(k)}}$$

$$p_{10} = \frac{p_6}{p_5}$$

$$p_{11} = \frac{\sum_{k=1}^{K} \left(f_k - p_5\right)^3 s(k)}{Kp_6^3}$$

$$p_{12} = \frac{\sum_{k=1}^{K} \left(f_k - p_5\right)^4 s(k)}{Kp_6^4}$$

$$p_{13} = \frac{\sum_{k=1}^{K} \left(f_k - p_5\right)^{1/2} s(k)}{K\sqrt{p_6}}$$

$$p_{14} = \sqrt{\frac{\sum_{k=1}^{K} \left(f_k - p_5\right)^2 s(k)}{\sum_{k=1}^{K} s(k)}}$$

$s(k)$ is a spectrum for $k = 1, 2, \ldots, K$,
$K$ is the number of spectrum lines
$f_k$ is the frequency value of the $k$th spectrum line

University of Guilan

# ویژگی آماری در حوزه فرکانس

- P1 : فرکانس متوسط که بیانگر انرژی ارتعاشات در حوزه فرکانس است
- ویژگی های P2 تا P4، P6 و P11 تا P13 : بیانگر همگرایی طیف توان که بیانگر انرژی طیف فرکانسی است.
- ویژگی هایP5 و P7 تا P9: بیانگر تغییر موقعیت فرکانس های اصلی (غالب در طیف فرکانسی) هستند.
- این ویژگی های می توانند عیب های مکانیکی زیادی را نشان دهند. عیب می تواند سبب تغییر در تمام طیف فرکانس و یا طیف توان شود.

# پردازش سیگنال در حوزه فرکانس - زمان

- با وجود آنکه FT به طور گسترده ای در استخراج طیف فرکانسی استفاده می شود، اما این روش محدود به سیگنال های ایستا بوده و برای پردازش سیگنال های عیب ماشین آلات غیر ایستا (Nonstationary) نامناسب است.
- همچنین، طیف فرکانسی به دست آمده از FT نمی تواند تغییر هر فرکانس را با زمان نشان دهد.
- برای حل این مشکل، روش های پردازش سیگنال در حوزه فرکانس - زمان معرفی شده اند.

# پردازش سیگنال در حوزه فرکانس - زمان

- روش های کلاسیک تحلیل فرکانس – زمان عبارتند از:

- Short-time Fourier Transform (SFT)
- Wigner–Ville distribution
- Wavelet Analysis
  - *Wavelet Transform*
  - *Wavelet Packet Transform*
- Hilbert–Huang transform
  - *Empirical Mode Decomposition (EMD)*
  - *Ensemble Empirical Mode Decomposition (EEMD)*

# تبدیل فوریه زمان کوتاه

- برای سیگنال x(t) تبدیل فوریه ایستا به شکل زیر است،

$$X(f)=\int_{-\infty}^{+\infty} x(t)\,\exp(-\mathrm{j}2\pi ft)\,dt$$

- یک تابع پنجره که تنها در یک زمان بسیار کوتاه غیر صفر است، در آن ضرب می شود $x(t)h^*(t-\tau)$

$$STFT_x(\tau,f)=\int_{-\infty}^{+\infty} x(t)\,h^*(t-\tau)\,\exp(-\mathrm{j}2\pi ft)\,dt$$

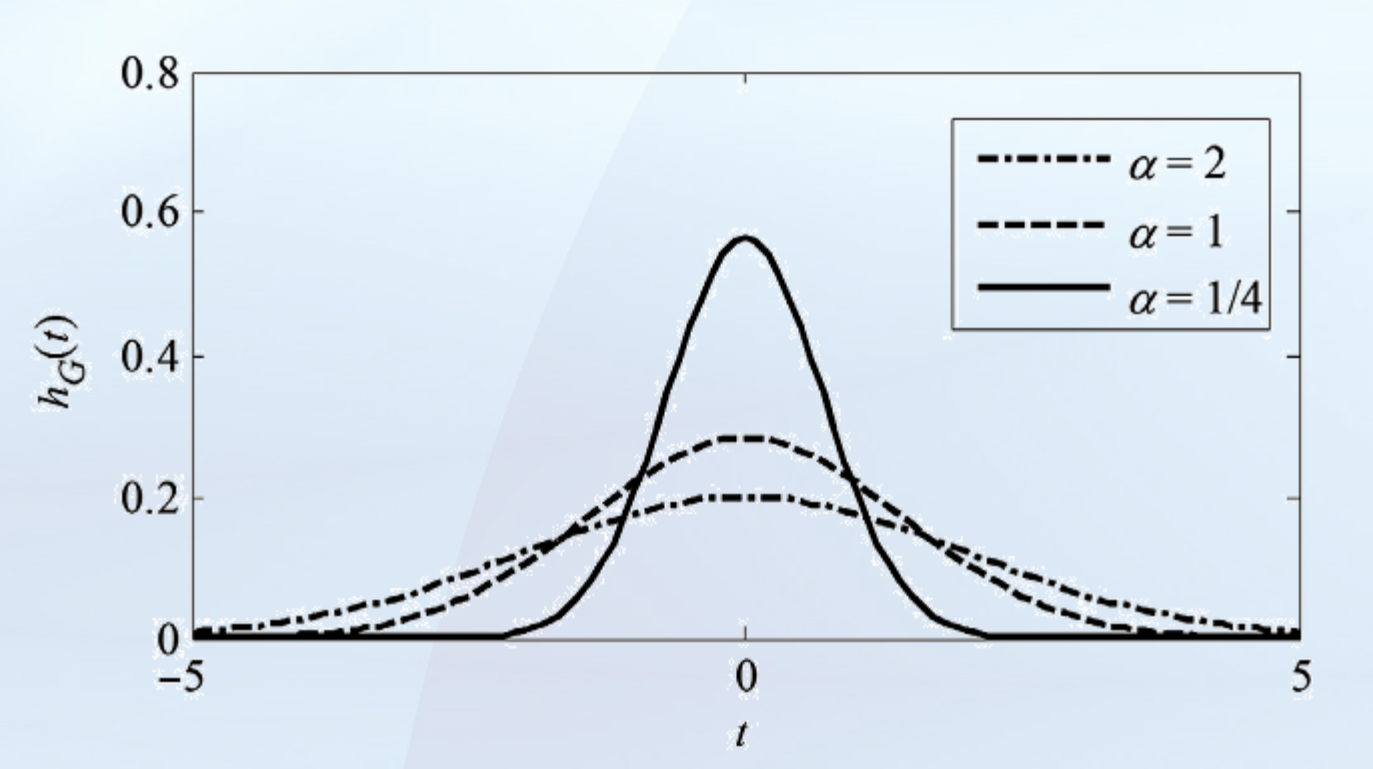
# تبدیل فوریه زمان کوتاه

- با توجه به اینکه STFT از تابع FT بدست آمده است بسیاری از مشخصات آن را همراه دارد.
- با این حال، عملکرد تحلیل STFT به شدت به انتخاب پنجره h (t) وابسته است.
- با توجه به اینکه تبدیل فوریه یک تابع گوسی، نیز گوسی است، انتخاب پنجره تابع گوسین می تواند انتخاب مناسبی باشد.

$$h_G(t) = \frac{1}{2\sqrt{\pi\alpha}} \exp\left(-\frac{t^2}{4\alpha}\right)$$

# تبدیل فوریه زمان کوتاه

- به ازای تغییرات $\alpha$ شکل تابع گوسین به صورت زیر است:



# تبدیل فوریه زمان کوتاه

- با در نظر گرفتن تابع پنجره و تبدیل فوریه آن به صورت:

$$h(t) \text{ and } H(f)$$

- می توان پهنای باند تغییرات فرکانسی $\Delta f$ را به صورت زیر تعریف کرد:

$$(\Delta f)^2 = \frac{\int f^2 |H(f)|^2 df}{\int |H(f)|^2 df}$$

که در آن مخرج کسر انرژی تابع پنجره $h(t)$ است.

- تفکیک (resolution) فرکانسی STFT توسط $\Delta f$ تعیین می شود.

# تبدیل فوریه زمان کوتاه

- به صورت مشابه، تفکیک زمانی STFT توسط $\Delta t$ تعیین می شود.

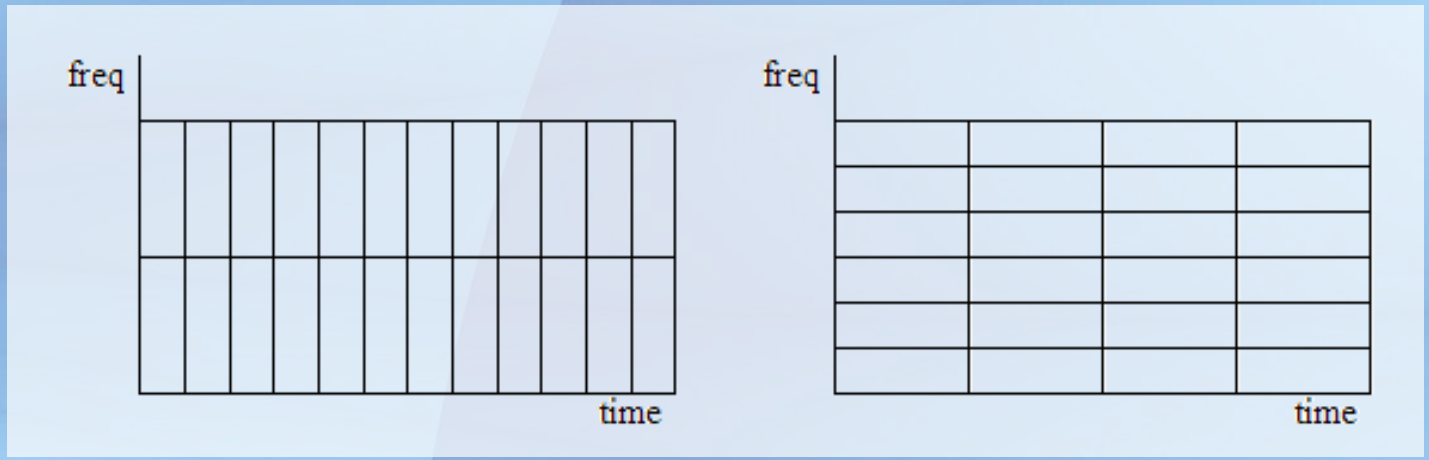
$$(\Delta t)^2 = \frac{\int t^2 |h(t)|^2 dt}{\int |h(t)|^2 dt}$$

- که در آن مخرج کسر انرژی تابع پنجره h(t) است.
- باید به این نکته توجه نمود که مقدار $\Delta t$ و $\Delta f$ به صورت همزمان نمی توانند کوچک شوند و باید در قید زیر محدود شوند

$$\text{Time-Bandwidth product} = \Delta t \Delta f \geq \frac{1}{4\pi}$$

# تبدیل فوریه زمان کوتاه

- یکی از معایب STFT داشتن تفکیک ثابت است.
- عرض تابع پنجره بیانگر نحوه نمایش سیگنال بوده به صورتی که تعیین کننده تفکیک فرکانسی خوب (قطعات فرکانسی در چه فرکانسی جدا می شوند) و یا تفکیک زمانی مناسب (زمان تغییر فرکانس) است.



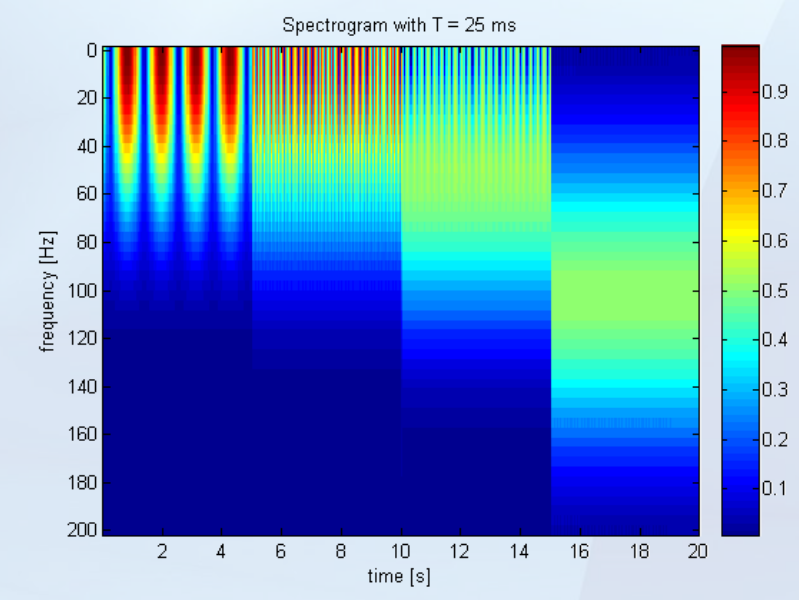
# تبدیل فوریه زمان کوتاه

- یک پنجره گسترده، تفکیک فرکانس را بهتر، اما تفکیک زمان کم را می کند. (تبدیل باریک)

- یک پنجره باریک، تفکیک زمان را خوب ولی تفکیک فرکانسی را تضعیف می کند. (تبدیل گسترده)

# تبدیل فوریه زمان کوتاه

$$x(t) = \begin{cases} \cos(2\pi 10t) & 0\,\mathrm{s} \le t < 5\,\mathrm{s} \\ \cos(2\pi 25t) & 5\,\mathrm{s} \le t < 10\,\mathrm{s} \\ \cos(2\pi 50t) & 10\,\mathrm{s} \le t < 15\,\mathrm{s} \\ \cos(2\pi 100t) & 15\,\mathrm{s} \le t < 20\,\mathrm{s} \end{cases}$$




- مثال: تابع x(t) شامل ۴ تابع زمانی در فرکانس های ۱۰، ۲۵، ۵۰ و ۱۰۰ Hz است. فرکانس نمونه برداری ۴۰۰ Hz و پنجره آن ۲۵ ms است.

# توزیع ویگنر- ویله

- Wigner–Ville distribution
- یک ابزار تجزیه و تحلیل فرکانسی قدرتمند است که بر روی توزیع انرژی کامل یک سیگنال در یک زمان و فرکانس خاص تمرکز می کند.
- WVD دارای تفکیک بالای چگالی انرژی لحظه ای در هر دو حوزه زمان و فرکانس است.

# توزیع ویگنر- ویله

- با فرض تابع همبستگی لحظه ای یک سیگنال حوزه زمان x(t) به صورت زیر:

$$R_x(t,\tau)=E\left[x\left(t+\frac{\tau}{2}\right)x^*\left(t-\frac{\tau}{2}\right)\right]$$

"*" denotes complex conjugate in Hilbert space

- با تبدیل فوریه این تابع خواهیم داشت:

$$S_x(t,\omega)=\frac{1}{2\pi}\int_{-\infty}^{\infty}R_x(t,\tau)\exp(-j\omega\tau)d\tau$$

- که در آن S تابع چگالی طیف توان است.

# توزیع ویگنر- ویله

- باید به این نکته توجه نمود که یافتن میانگین نمونه ها غیرممکن است. بنابراین با جایگذاری دو رابطه داریم:

$$WD_x(t,\omega)=\frac{1}{2\pi}\int_{-\infty}^{\infty}x\left(t+\frac{\tau}{2}\right)x^*\left(t-\frac{\tau}{2}\right)\exp(-j\omega\tau)d\tau$$

- تابع WVD وابسته به زمان و فرکانس است و بر روی یک بازه بینهایت از $\tau$ تعریف شده و بسیار دورتر از زمان محلی t است.

# توزیع ویگنر- ویله

- با محدود کردن بازه انتگرال گیری، این تابع به شکل:

Pseudo Wigner–Ville distribution (PWD)

تبدیل می شود

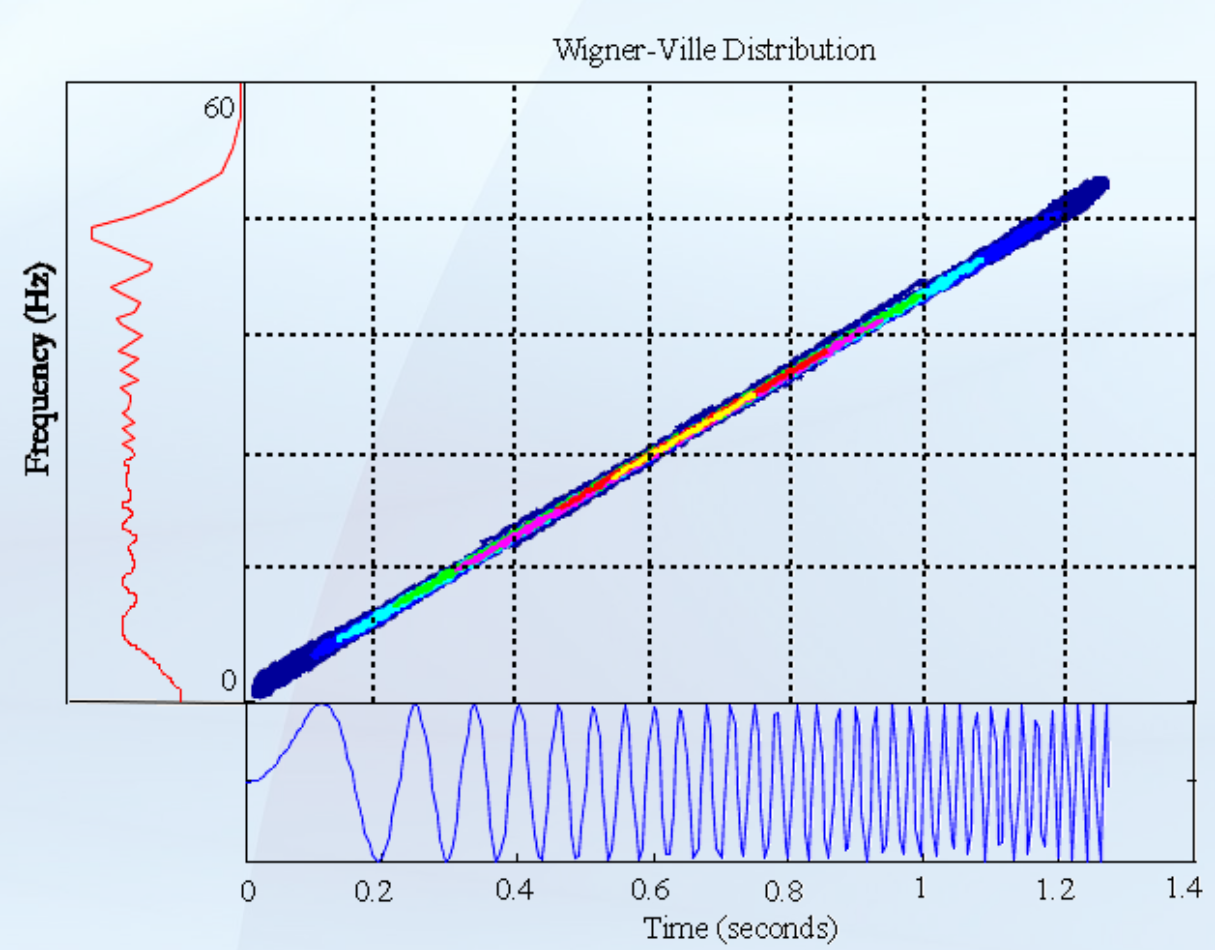
$$PWD_x(t,\omega)=\frac{1}{2\pi}\int_{-\infty}^{+\infty} WD_x(t,\Omega)W_h(0,\ \omega-\Omega)d\Omega$$

که در آن Wh مقدار WVD با پنجره h(t) است.

- PWD توزیع انرژی یک سیگنال در صفحه فرکانس زمانی است.

# توزیع ویگنر- ویله

- Wigner-Ville distribution of a simple chirp signal



# تبدیل موجک

- تحلیل موجک یا Wavelet analysis :
  - تحلیل با چند تفکیک متفاوت از سیگنال را در باند فرکانسی مستقل فراهم می کند.
  - در این نوع تجزیه داده ها، در هر مرحله از عملیات، فیلترهای پایین گذر و و باند عبور به طور همزمان اعمال می شود.
  - توابع مبنای تبدیل موجک WT، امواج کوچک در زمانهای مختلف هستند.
  - این موج ها توسط توابع تغییر مقایس و تبدیل ایجاد می شوند.
  - در نتیجه WT در هر دو حوزه زمان و فرکانس است.

# تبدیل موجک

- با تعریف: $g(t) \in L^2(R)$ $x(t) \in L^2(R)$ $R \in \square$

ضرب داخلی دو تابع x(t) و g(t) :

$$\langle x(t), g(t) \rangle = \int_{-\infty}^{+\infty} x(t)\, g(t)\, dt$$

- در صورتی که تابع g(t) به صورت

$$h^*(t-\tau)\exp(-j2\pi ft)$$

انتخاب شود، ضرب داخلی تبدیل به تبدیل فوریه زمان کوتاه یا STFT خواهد شد.

# تبدیل موجک

- حال با تعریف یک تابع پایه مناسب g(t) به شکل تابع $\Psi$ که به آن تابع موجک گوییم داریم:

$$\psi_{a,b}(t)=|a|^{-1/2}\psi\left(\frac{t-b}{a}\right),\ a,b\in R$$

- شرایط پذیرش:

$$\psi(t)\in L^2(R)$$

مقدار تابع در $\pm\infty$ صفر می شود:

$$\int_{-\infty}^{+\infty}\psi(t)dt=0$$

$$\int_{-\infty}^{+\infty}\psi(t)dt=0$$

$$C_\psi=\int_{-\infty}^{+\infty}\frac{|\hat{\psi}(\omega)|^2}{|\omega|}d\omega<\infty$$

$\hat{\psi}(\omega)$ is FT of $\psi(t)$

# تبدیل موجک

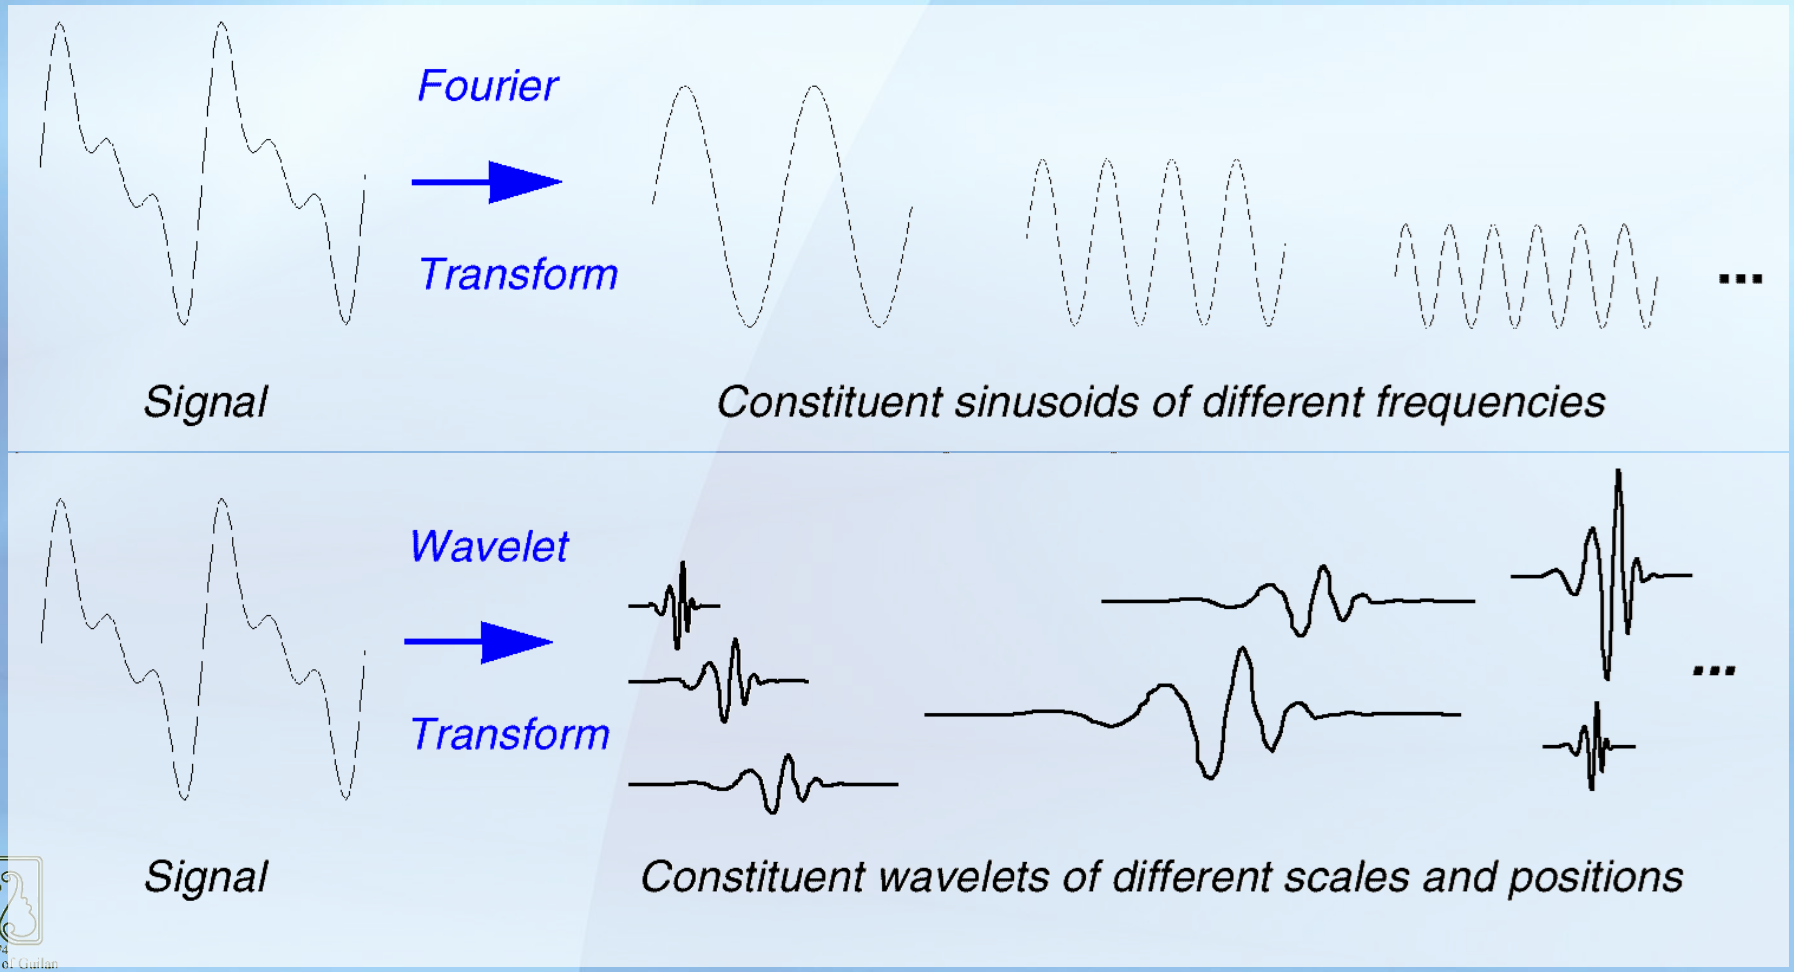
- تبدیل موجک تابع x(t) به صورت زیر بدست خواهد آمد:

$$WT_x(b,a) = |a|^{-1/2} \int_{-\infty}^{+\infty} x(t)\psi^*\left(\frac{t-b}{a}\right)dt = \langle x, \psi_{a,b} \rangle, \; x(t) \in L^2(R)$$

$$a, b \in R \text{ and } a \neq 0$$

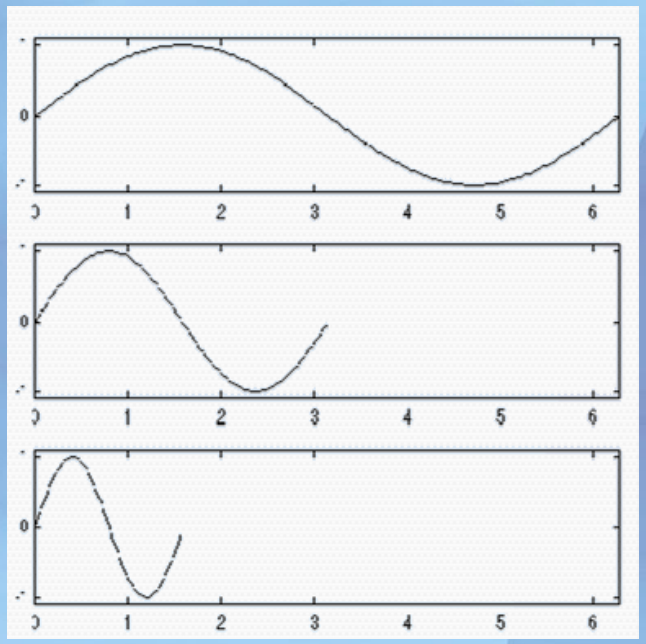
# تبدیل موجک

- تفاوت عملکرد تبدیل فوریه و تبدیل موج



# تبدیل موجک

- مقیاس گذاری (Scaling):
  - تبدیل موجک یک مقایس زمانی از سیگنال ارائه می کند.
  - مقایس گذاری به معنی بازکردن و یا متراکم کردن سیگنال است.
    - مثال: فاکتور a برای موج سینوسی:



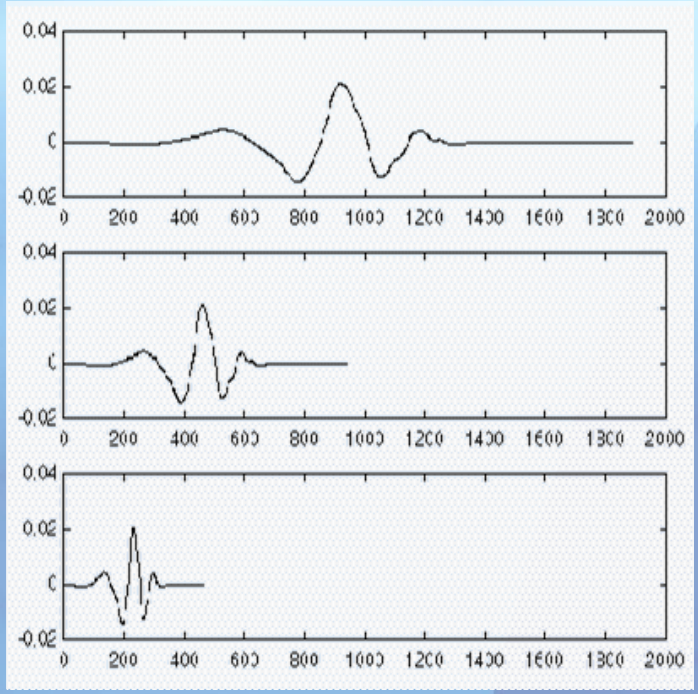

$$f(t) = \sin(t) \;;\; a = 1$$

$$f(t) = \sin(2t) \;;\; a = 1/2$$

$$f(t) = \sin(4t) \;;\; a = 1/4$$

# تبدیل موجک

- فاکتور مقیاس به صورت زیر در تبدیل موجک عمل می کند.




$$f_{(t)} = \Psi(t) \;\; ; \;\; a = 1$$

$$f_{(t)} = \Psi(2t) \;\; ; \;\; a = 1/2$$

$$f_{(t)} = \Psi(4t) \;\; ; \;\; a = 1/4$$

# تبدیل موجک

- پارامتر مقیاس در تجزیه و تحلیل موجک، مانند مقایس نقشه ها است.
- مقیاس بالا نشان دهنده دید کلی و فاقد جزییات سیگنال است
- مقایس پایین نشان دهنده یک دید با جزییات و تفصیل بیشتر است.

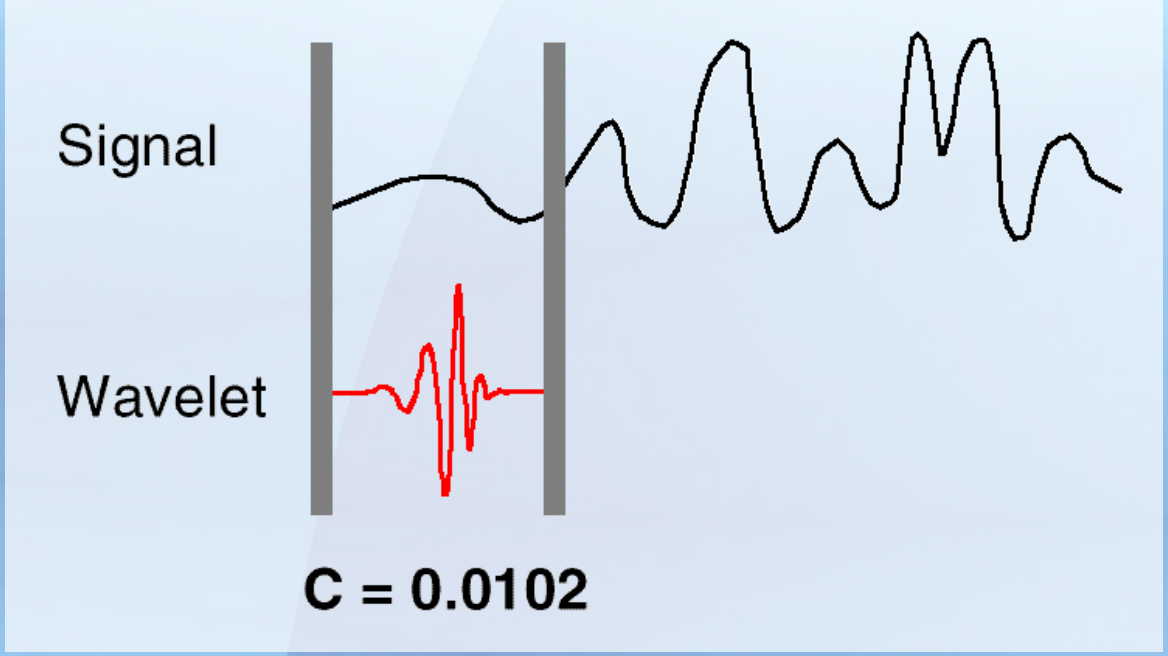
# تبدیل موجک

- تبدیل موجک پیوسته به صورت یک مجموع بر روی مجموعه تمام زمان سیگنال است که در یک تابع موجک منتقل و مقایس بندی شده ضرب شده است.

- مرحله ۱: یک موجک را بیابید و آن را با بخشی در ابتدای سیگنال اولیه مقایسه کنید

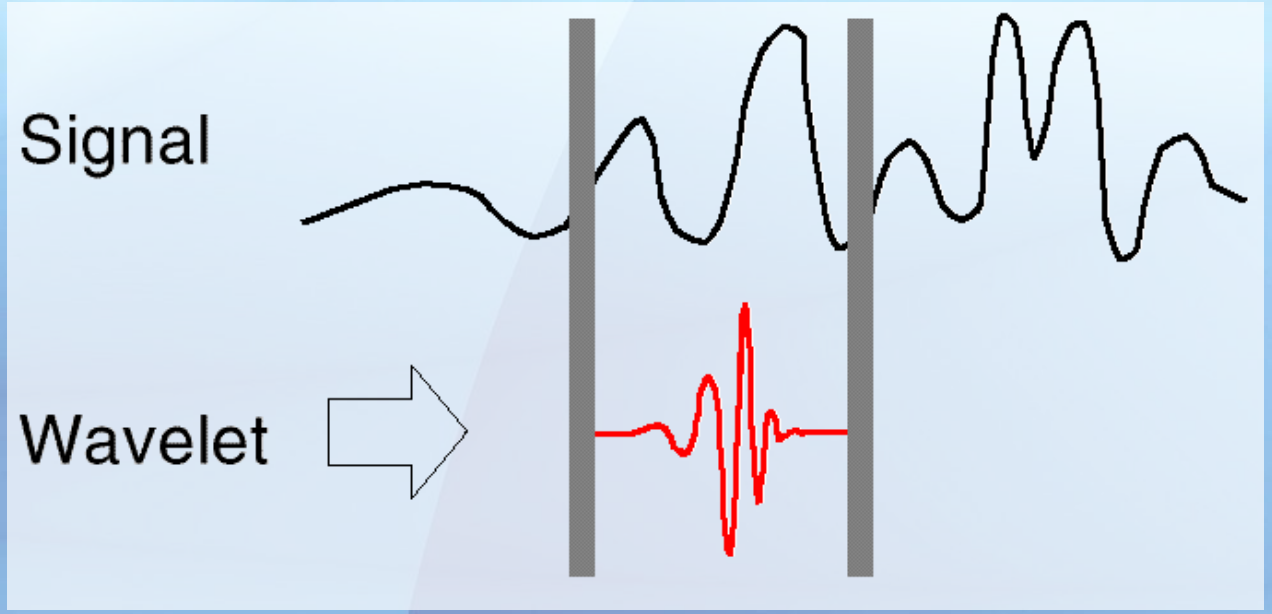
# تبدیل موجک

- مرحله ۲: مقدار عدد C را محاسبه کنید، که نشان دهنده چگونگی همبستگی موجک با این بخش سیگنال است. مقدار آن بزرگتر، نشانگر تشابه بیشتر است.



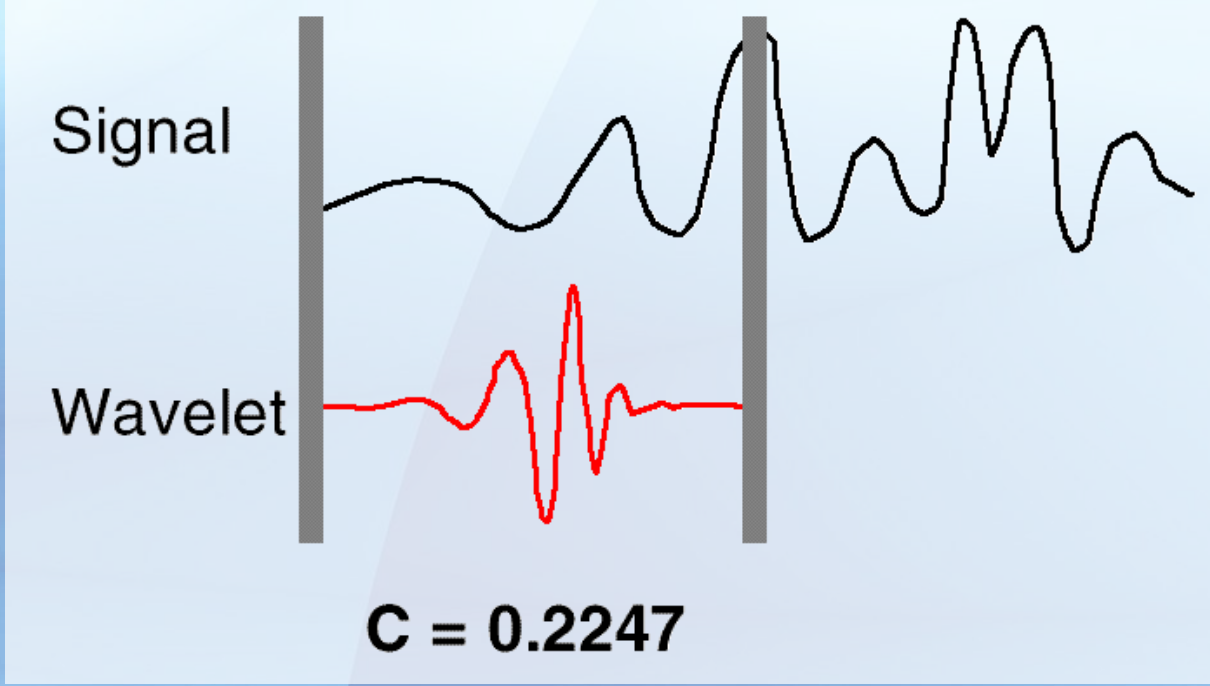
# تبدیل موجک

- مرحله ۳: موجک را به سمت راست منتقل کرده و مراحل ۱ و ۲ را تا زمانی که کل سیگنال را پوشش دهد، تکرار کنید.



# تبدیل موجک

- مرحله ۴: موجک را مقیاس بندی (بکشید) و مراحل ۱ تا ۳ را تکرار کنید



# تبدیل موجک

- یک راه حل آسان تر آن است که سیگنال پیوسته، گسسته شود.
- شبکه ای از مقادیر گسسته که به آن شبکه دوتایی یا dyadic grid گویند، استفاده می شود:

$$Z = \{\ldots, -2, -1, 0, 1, 2, \ldots\}$$

$$a = 2^j,\ b = 2^j k,\ j,\ k \in Z$$

$$\psi_{j,k}(t) = 2^{-j/2}\psi(2^{-j}t - k), \quad j, k \in Z$$

# تبدیل موجک

- Kronecker symbol:

$$\delta_{j,k} = \begin{cases} 1 & j = k \\ 0 & j \neq k \end{cases}, \quad j,k \in Z$$

- در این صورت تابع موجک یک تابع متعامد است اگر

$$\left\langle \psi_{j,k}, \psi_{l,m} \right\rangle = \delta_{j,l} \cdot \delta_{k,m}, \quad j,k,l,m \in Z$$

$$x(t) \in L^2(R)$$

$$x(t) = \sum_{j,k=-\infty}^{+\infty} c_{j,k} \psi_{j,k}(t)$$

# تبدیل موجک

- در این صورت ضریب تبدیل موجک $c_{j,k}$ به صورت زیر محاسبه می شود:

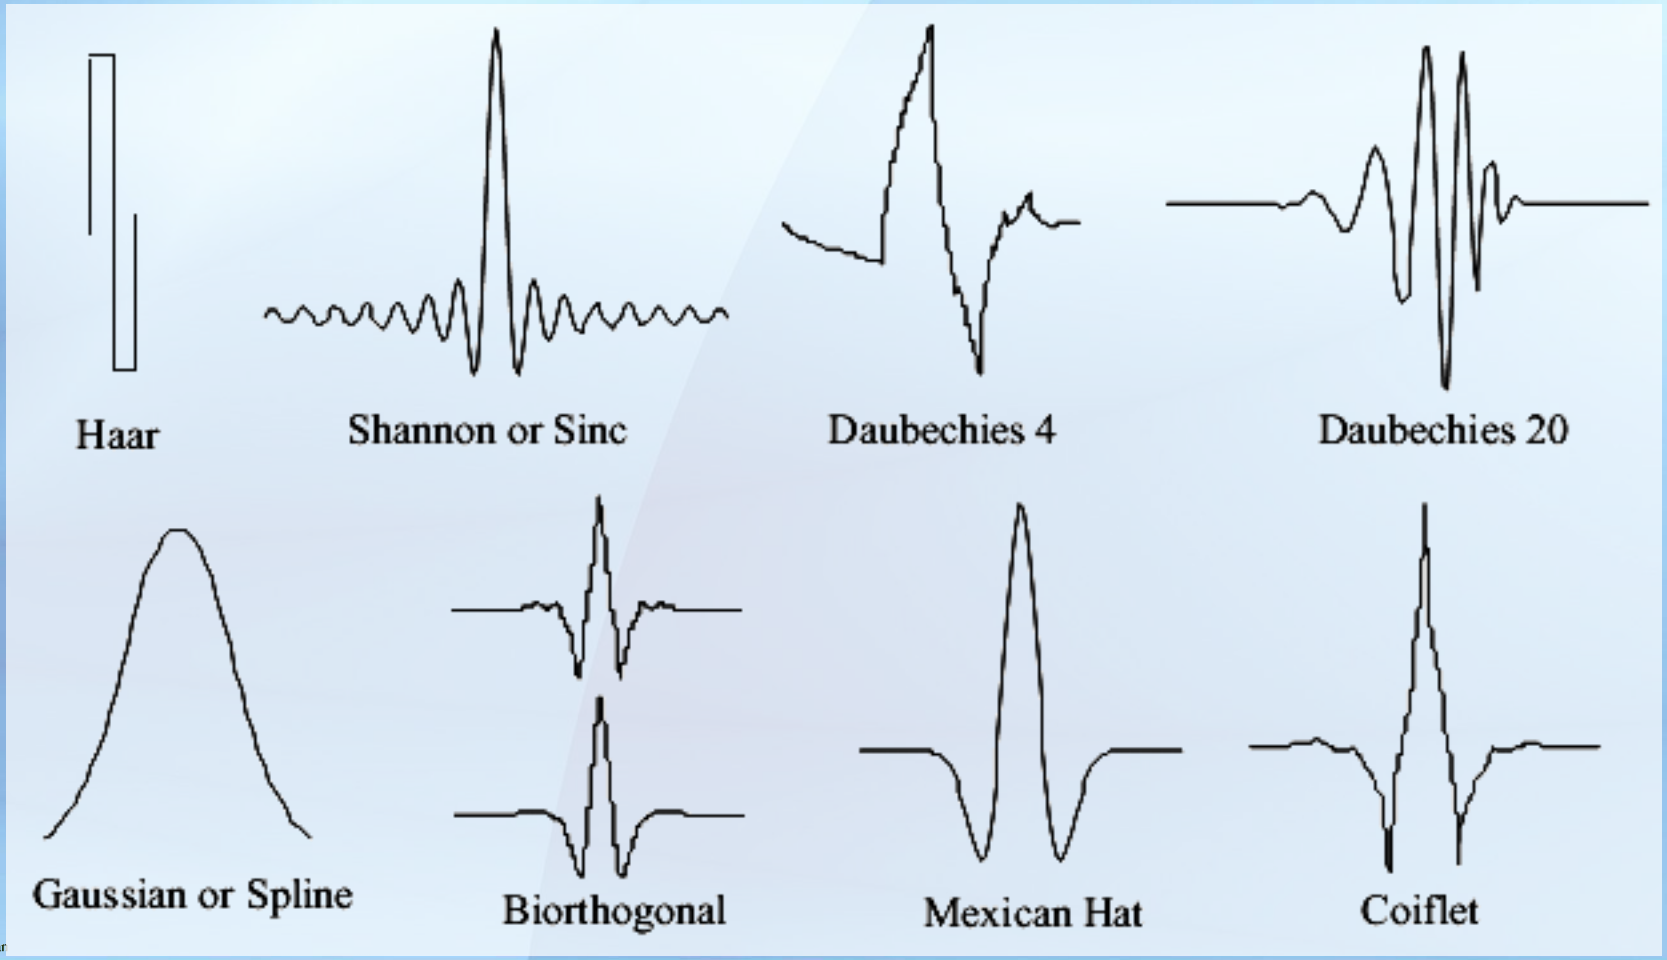
$$c_{j,k} = \left\langle x(t), \psi_{j,k}(t) \right\rangle$$

- با توجه به تابع انتگرال تبدیل موجک، ضریب تبدیل موجک $c_{j,k}$ برابر است با:

$$c_{j,k} = WT_x\left(\frac{k}{2^j}, \frac{1}{2^j}\right)$$

# تبدیل موجک

انواع تابع های موجک:



# تبدیل هیلبرت- هوانگ

- Hilbert–Huang transform

- تبدیل HHT به طور خاص برای تجزیه و تحلیل سیگنالهای غیر خطی و ناپایدار طراحی شده است.
- بخش اصلی HHT EMD است که می تواند هر سیگنال پیچیده را به تعداد محدود و غالبا کوچک از توابع حالت ذاتی یا IMF تجزیه کند.
- فرکانس لحظه ای که توسط HT مشخص می شود، می تواند معنای فیزیکی تغییر فاز محلی برای حالتهای ذاتی را بهتر از سایر سری های دیگر (غیر حالتهای ذاتی) نشان دهد.

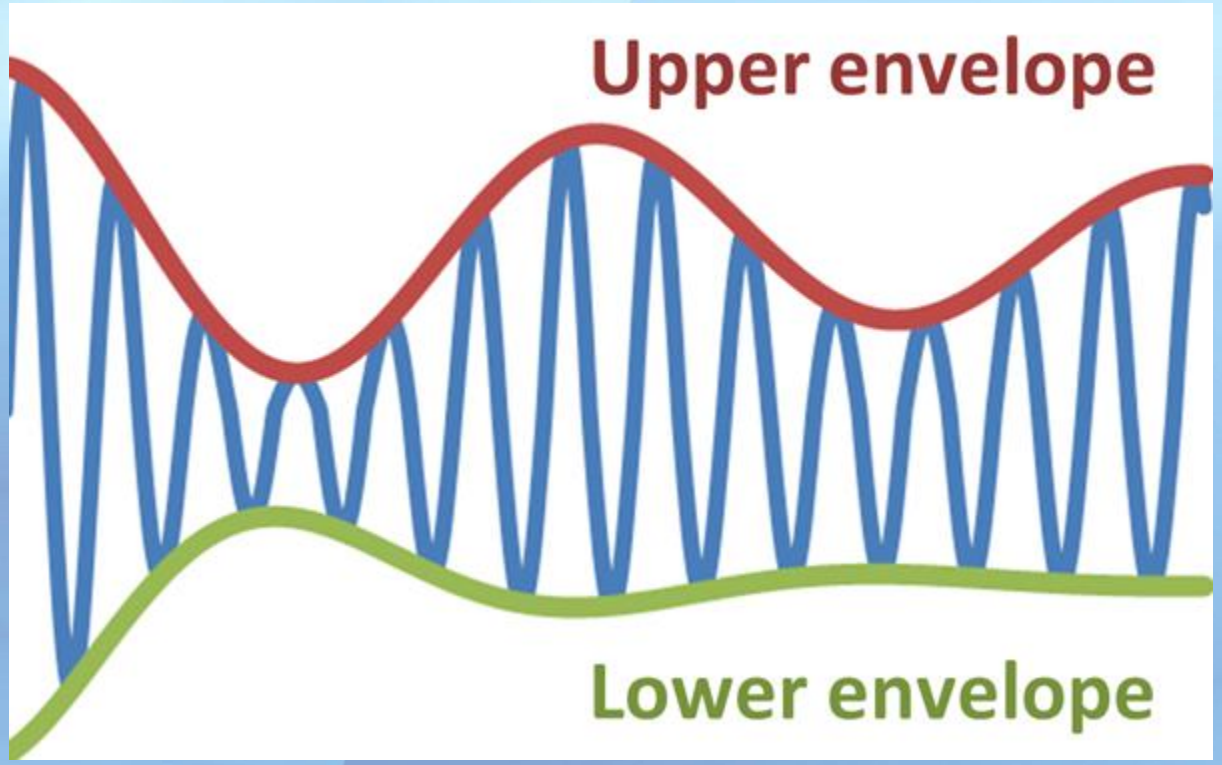
# تجزیه حالت تجربی

- Empirical Mode Decomposition

- تجزیه حالت تجربی EMD یکی از محبوب ترین روش های تجزیه و تحلیل فرکانس زمانی است.
- به طور کلی، یک سیگنال دامنه زمانی می تواند به یک مجموعه از توابع نوسانی در حوزه زمانی تجزیه شود، که به توابع حالت ذاتی یا IMF گویند.
- روش EMD یک روش پردازش سیگنال خود سازگار بوده که مناسب برای فرآیندهای آماری غیر خطی و غیر ایستا است.

# تجزیه حالت تجربی

- تعریف Envelope یا پوش



# تجزیه حالت تجربی

- یک مود ذاتی تابعی است اگر:

1. در کل داده، تعداد نقاط حداکثر و نقاط صفر با هم برابر و یا حداکثر در یکی تفاوت داشته باشند.
2. در هر نقطه میانگین از پوش بیشینه محلی و پوش کمینه محلی باید صفر باشد.

# تجزیه حالت تجربی

- The EMD Technique (Lei et al., 2013)
  - فرآیند جداسازی به صورت زیر است:
  - مرحله ۱: مقدار اولیه $r_0=x(t)$ و $i=1$ در نظر گرفته شود.
  - مرحله ۲: امین $i$ IMF تعیین شود = $C_i$
    - الف) مقدار $r_{i-1}$ = $h_{i(k-1)}$ و $k=1$ در نظر گرفته شود
    - ب) مقدار حداکثر و حداقل محلی پیدا شوند.
    - ج) پوش بیشینه و کمینه $h_{i(k-1)}$ با استفاده از میان یابی خط مکعبی تعیین شود

# تجزیه حالت تجربی

– د) مقدار متوسط $h_{i(k-1)}$ محاسبه شود

$$m_{i\,(k-1)} = \frac{h_{i\,(k-1)}^{\max} + h_{i\,(k-1)}^{\min}}{2}$$

– ه) مقدار $h_{ik}$ جدید محاسبه می شود

$$h_{ik} = h_{i\,(k-1)} - m_{i\,(k-1)}$$

– و) آیا IMF بدست آمده صحیح است؟

- خیر : k = k +1 و تکرار
- بله: به مرحله ۳ بروید

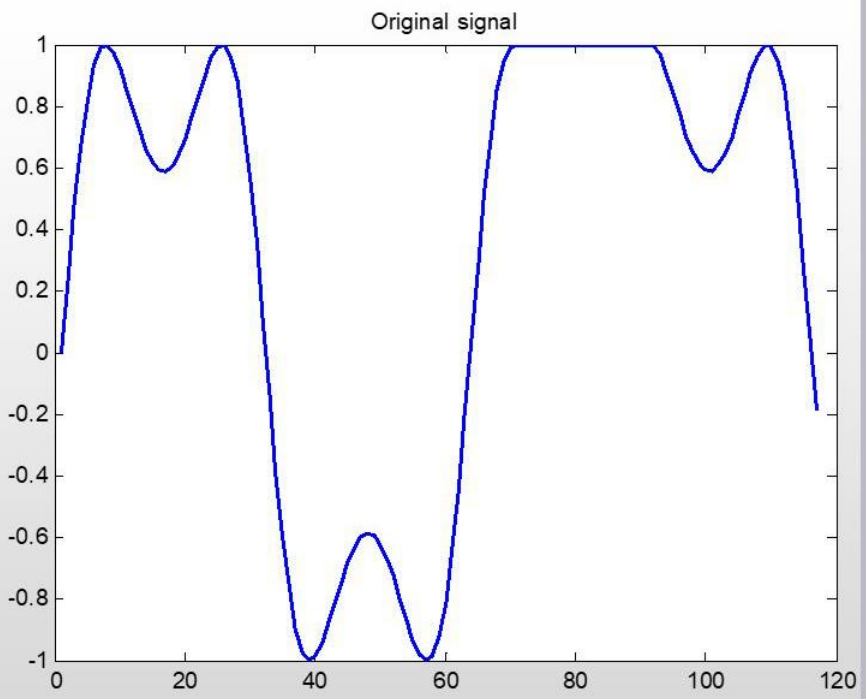
# تجزیه حالت تجربی

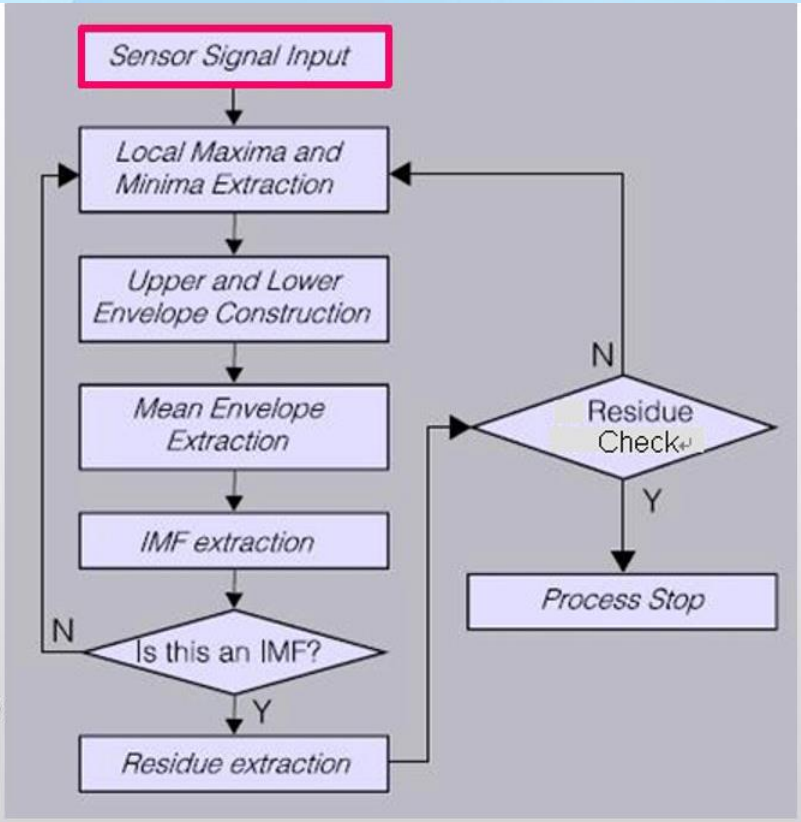
- مرحله ۳: مقدار باقیمانده $i+1$ امین محاسبه می شود:

$$r_{i+1} = r_i - c_i$$

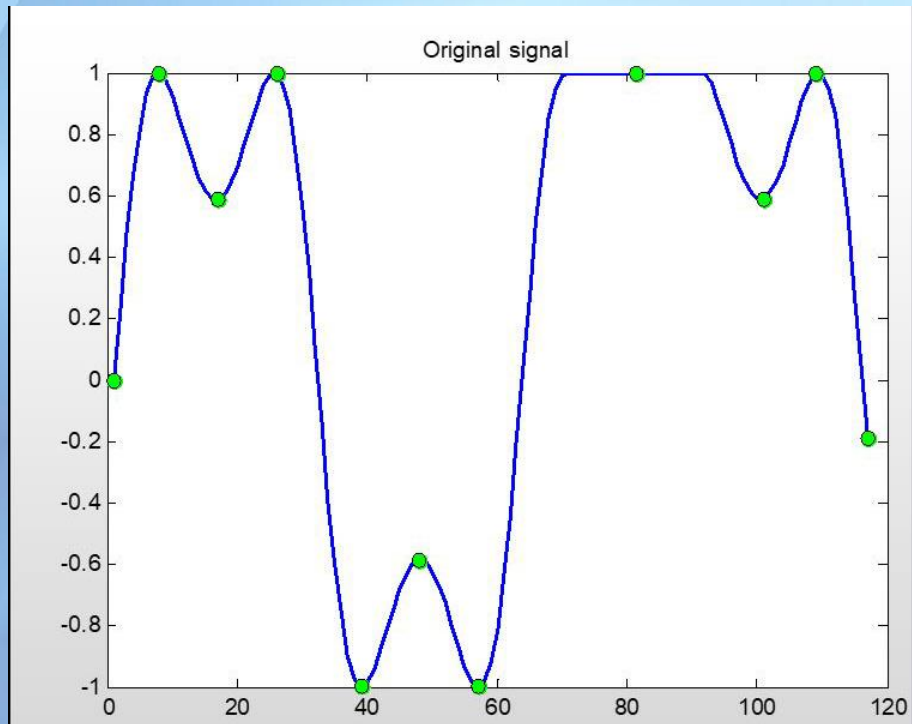
- مرحله ۴: اگر $r_{i+1}$ هنوز حداقل ۲ مقدار اکسیریمم داشته باشد به مرحله ۲ بازگشته و i=i+1 در نظر گرفته شود در غیر این صورت فرآیند جداسازی به پایان رسیده و $r_{i+1}$ باقیمانده سیگنال است.

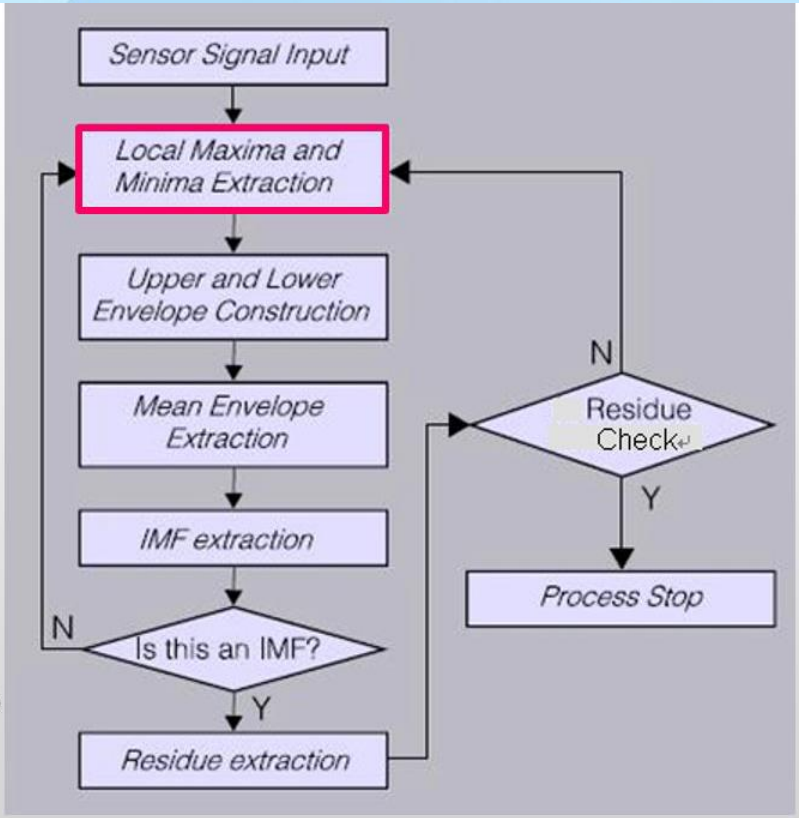
# EMD


Original signal
1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
0
20
40
60
80
100
120

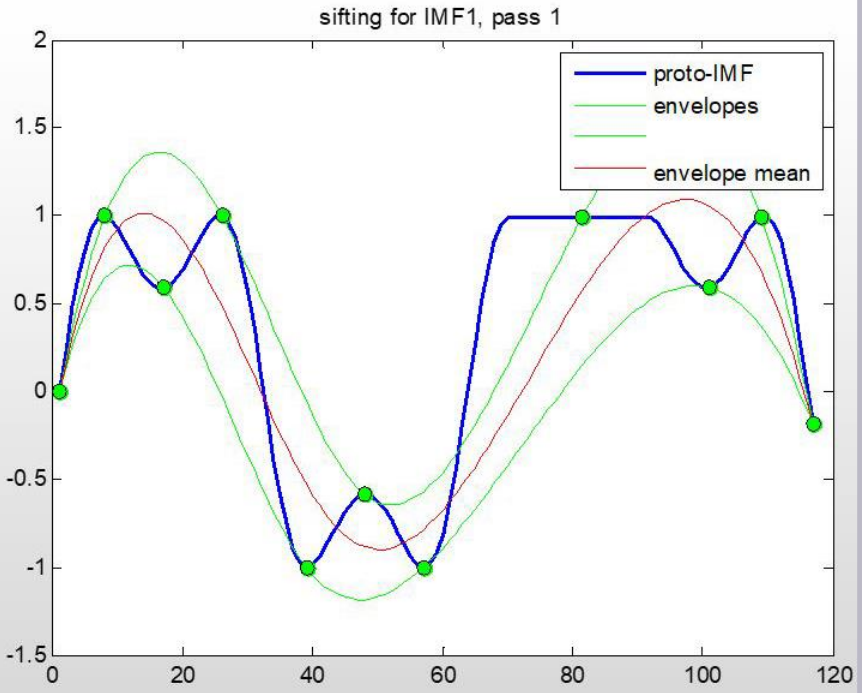

Sensor Signal Input
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

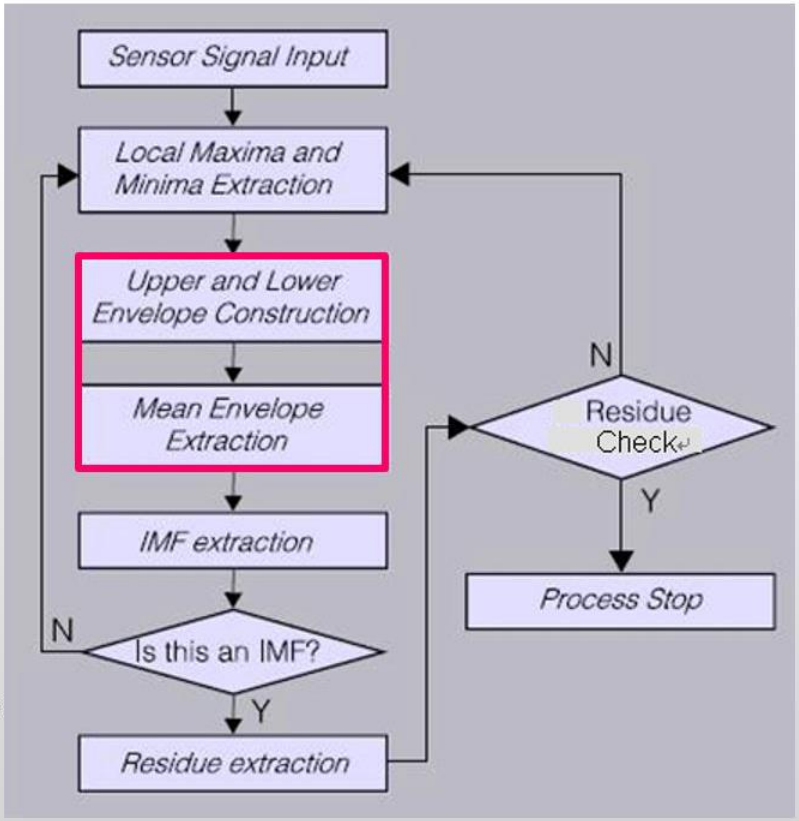
# EMD


Original signal
1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
0
20
40
60
80
100
120

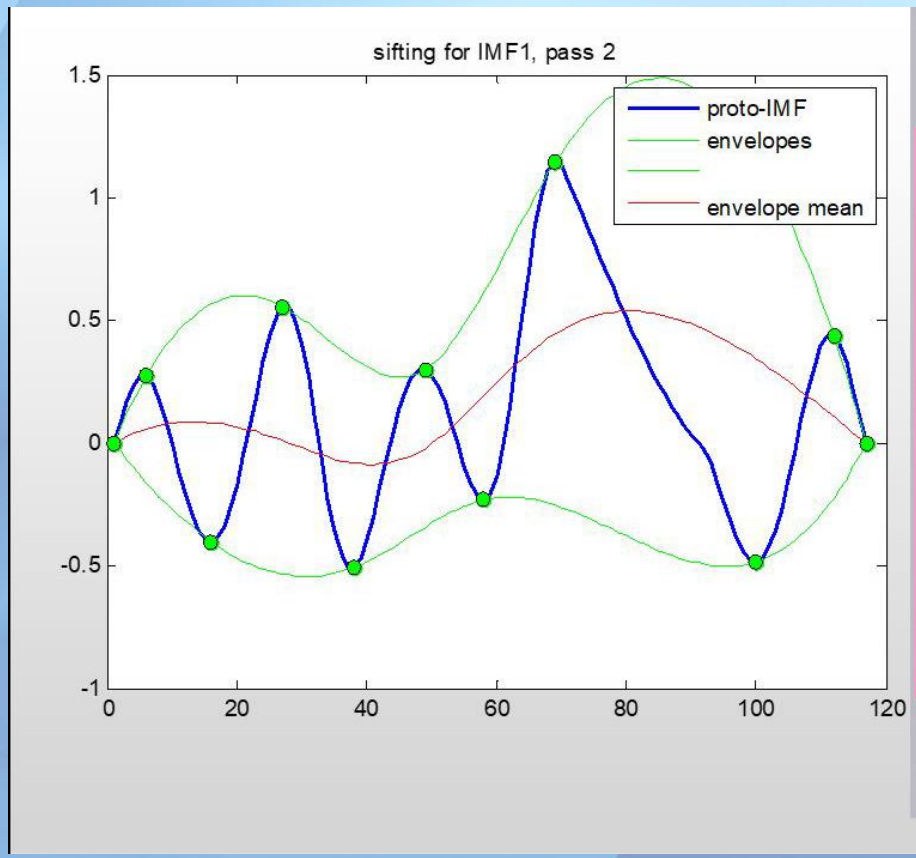

Sensor Signal Input
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

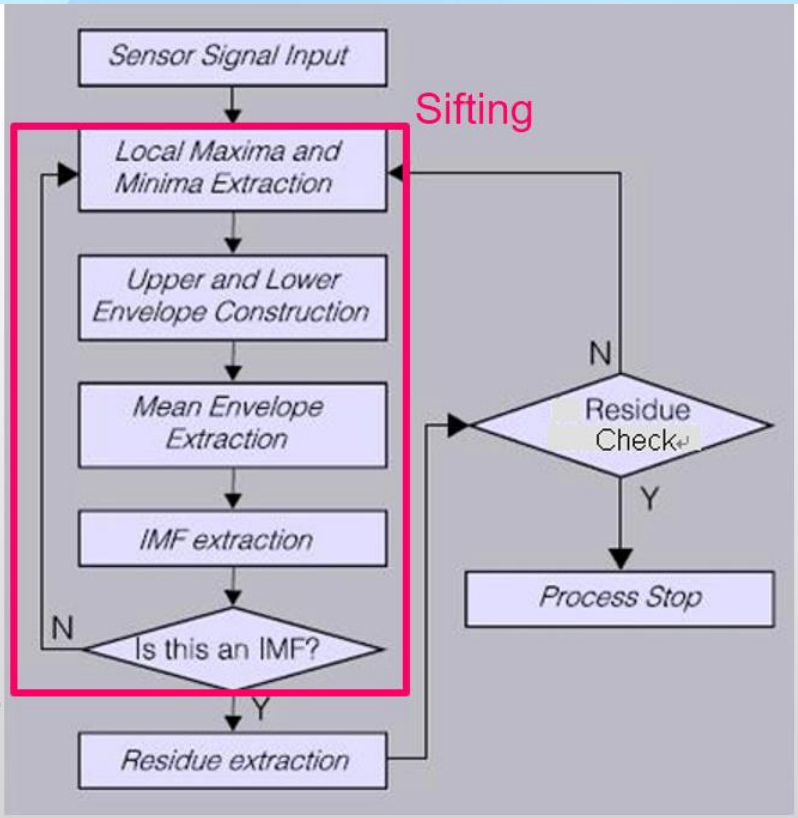
# EMD


sifting for IMF1, pass 1
proto-IMF
envelopes
envelope mean
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120

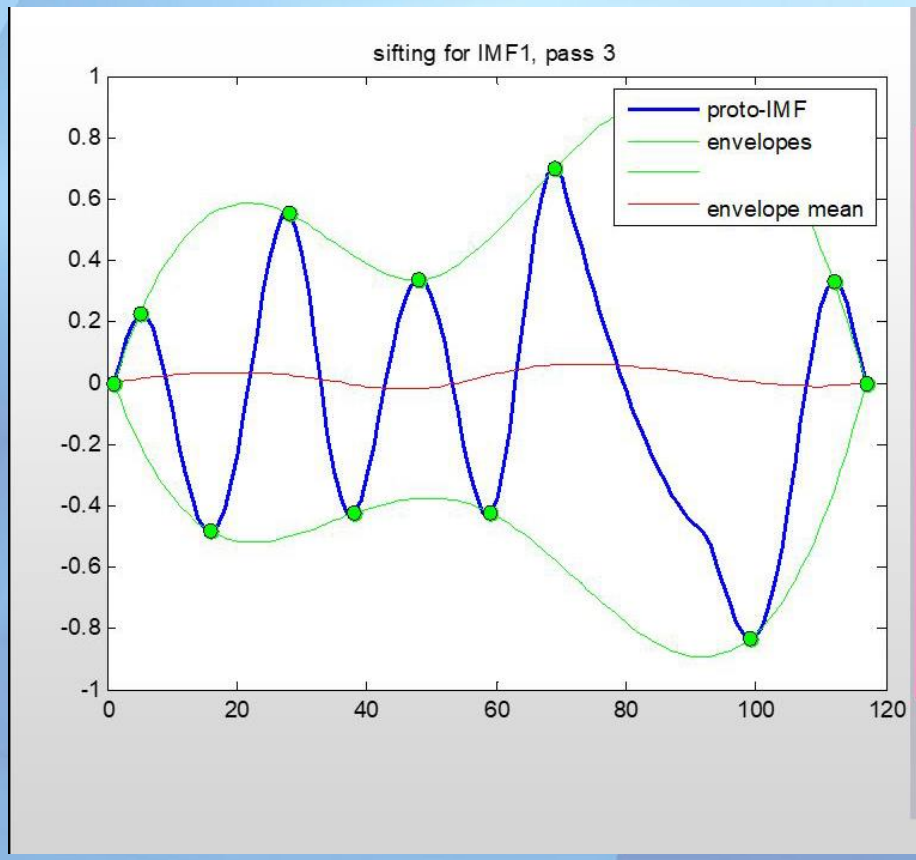

Sensor Signal Input
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

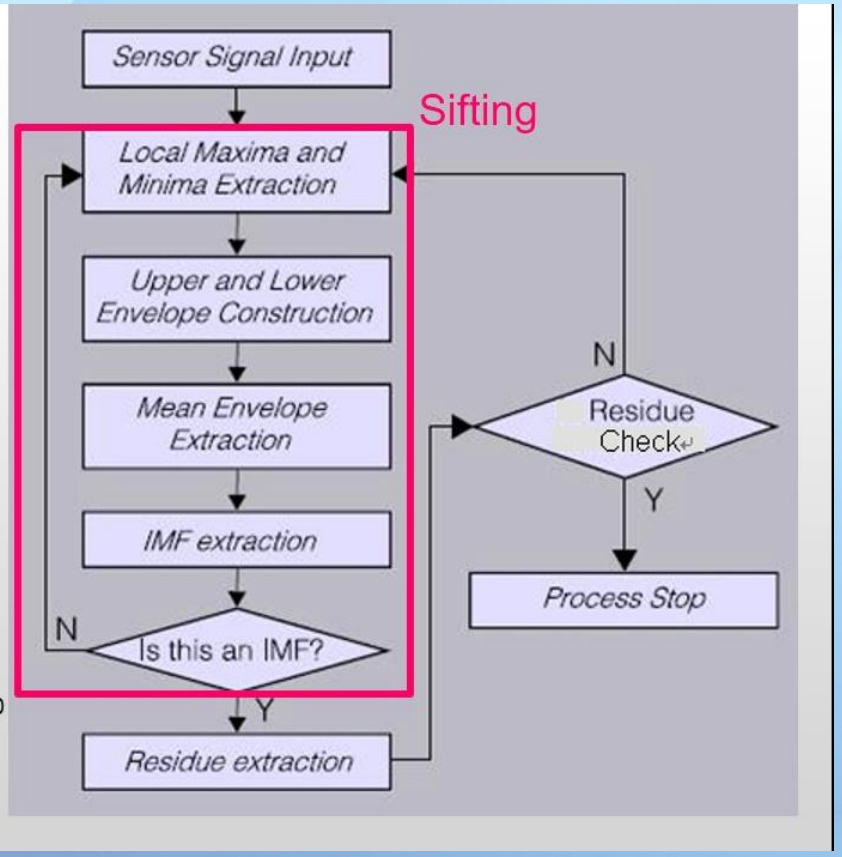
# EMD


sifting for IMF1, pass 2
proto-IMF
envelopes
envelope mean
1.5
1
0.5
0
-0.5
-1
0
20
40
60
80
100
120

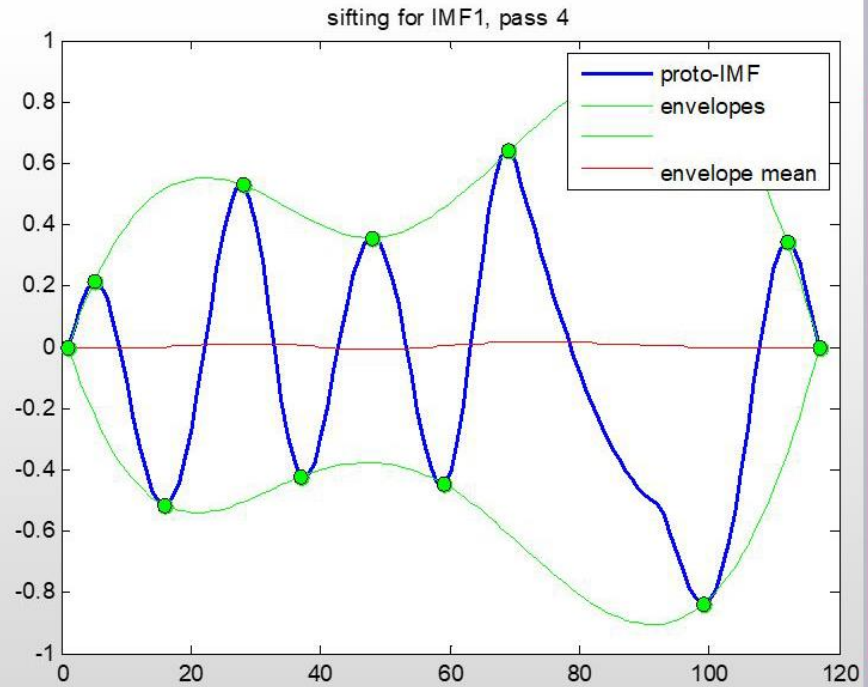

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
N
Is this an IMF?
Y
Residue extraction
N
Residue Check
Y
Process Stop

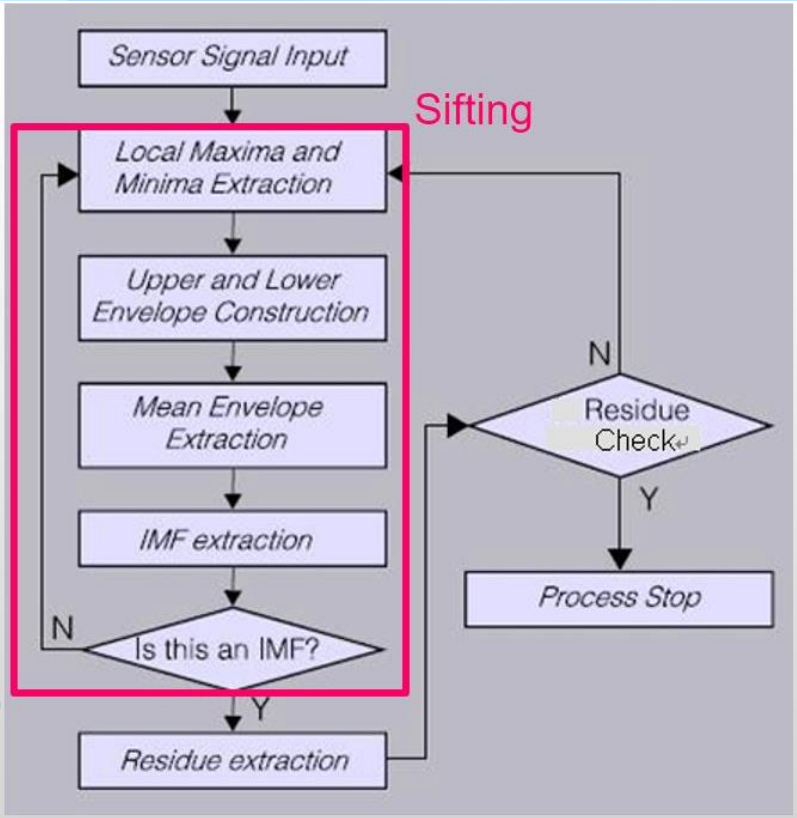
# EMD


sifting for IMF1, pass 3
proto-IMF
envelopes
envelope mean
1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
0
20
40
60
80
100
120

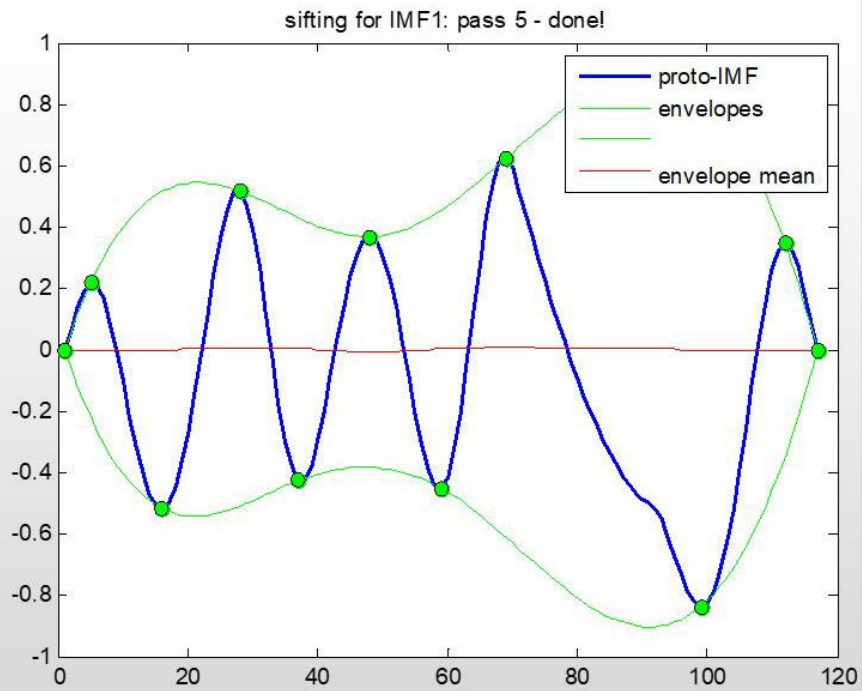

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

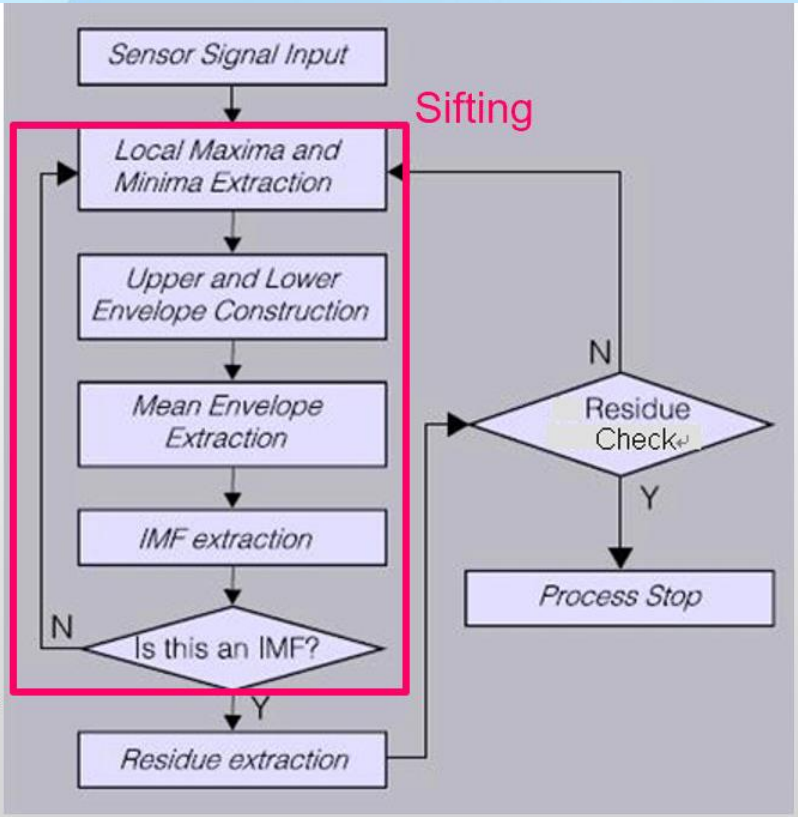
# EMD


sifting for IMF1, pass 4
proto-IMF
envelopes
envelope mean
1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
0
20
40
60
80
100
120

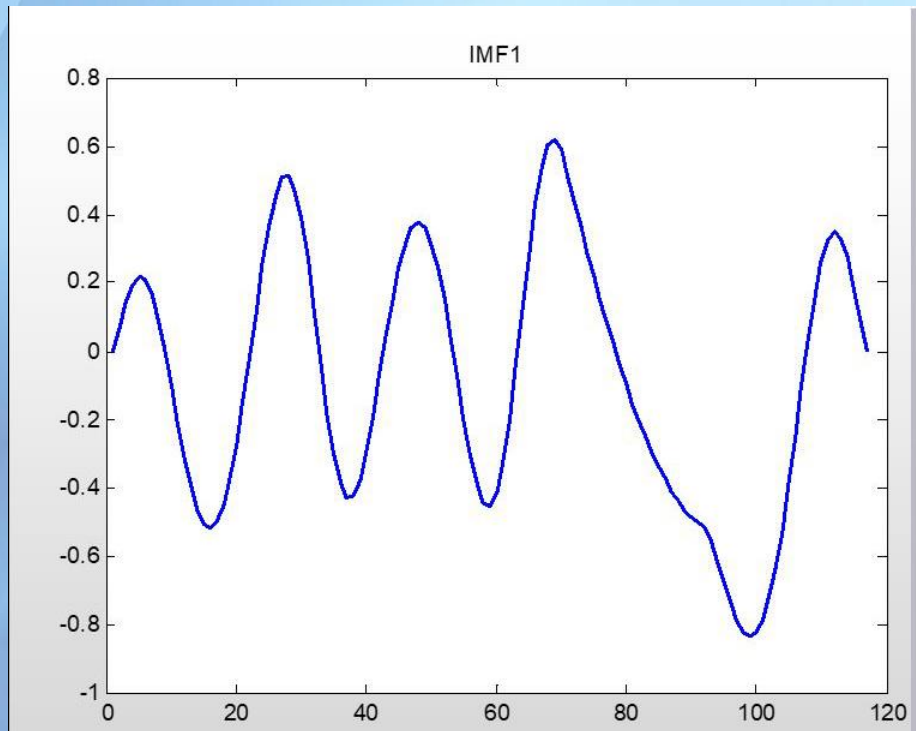

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
N
Is this an IMF?
Y
Residue extraction
N
Residue Check
Y
Process Stop

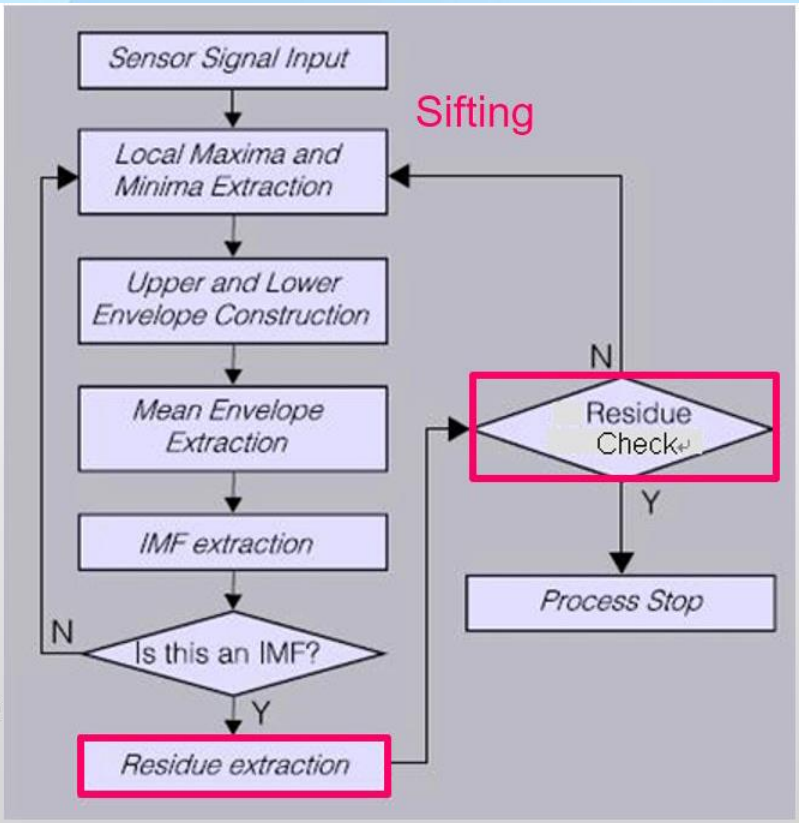
# EMD


sifting for IMF1: pass 5 - done!
proto-IMF
envelopes
envelope mean
1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
0
20
40
60
80
100
120

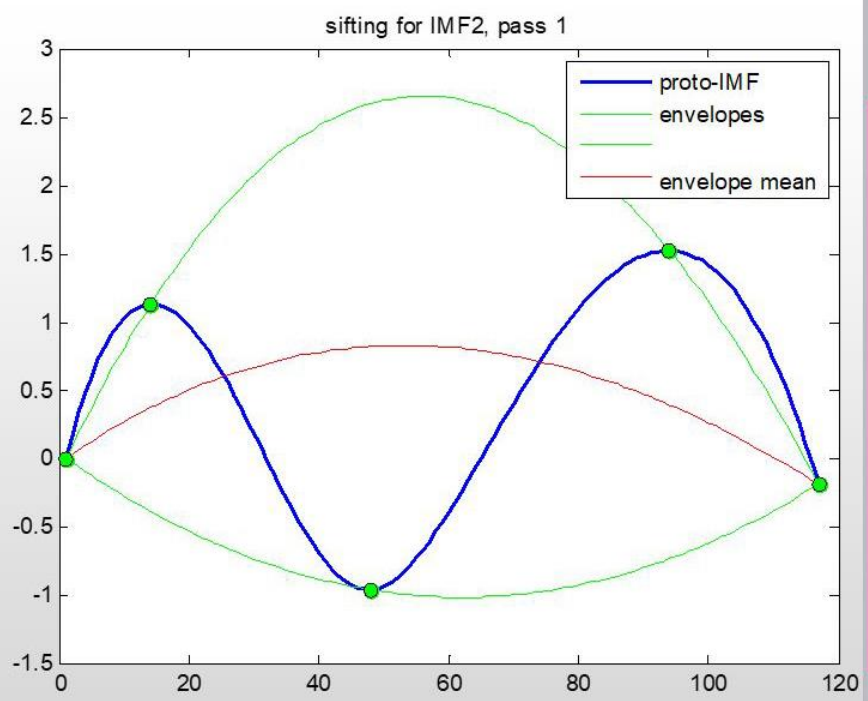

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
N
Is this an IMF?
Y
Residue extraction
N
Residue Check
Y
Process Stop

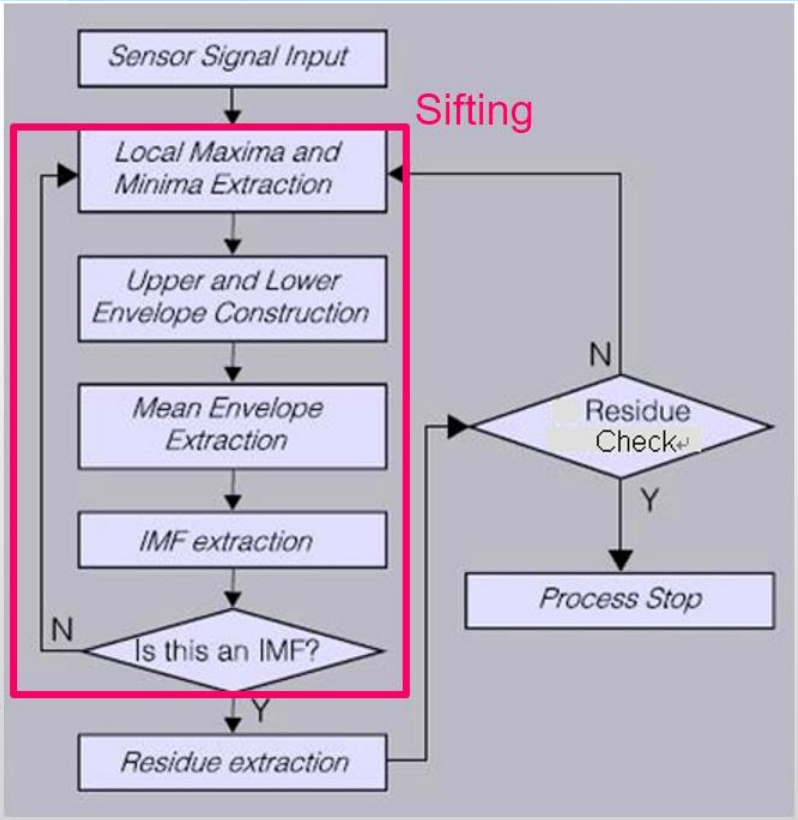
# EMD


IMF1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
0
20
40
60
80
100
120

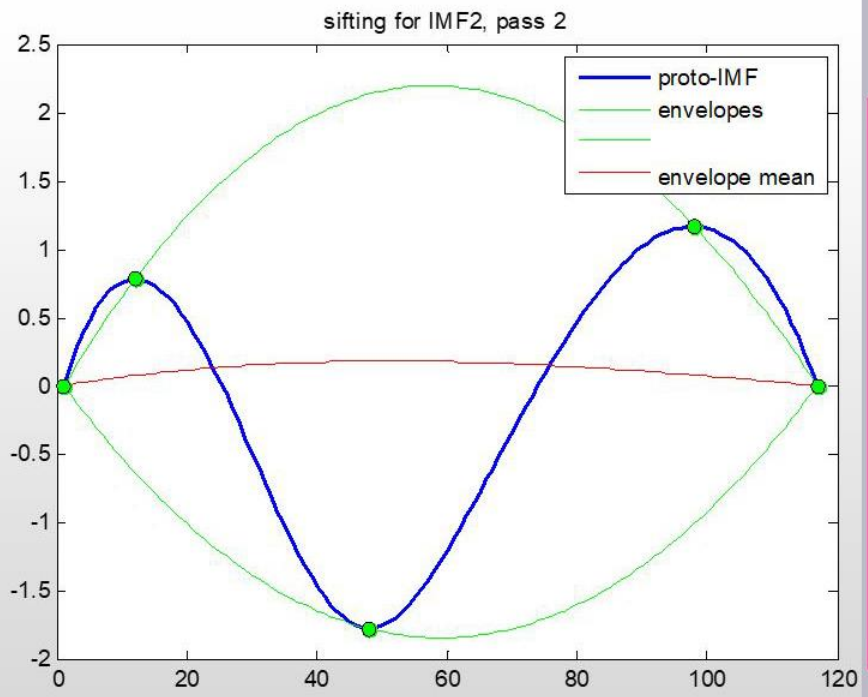

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

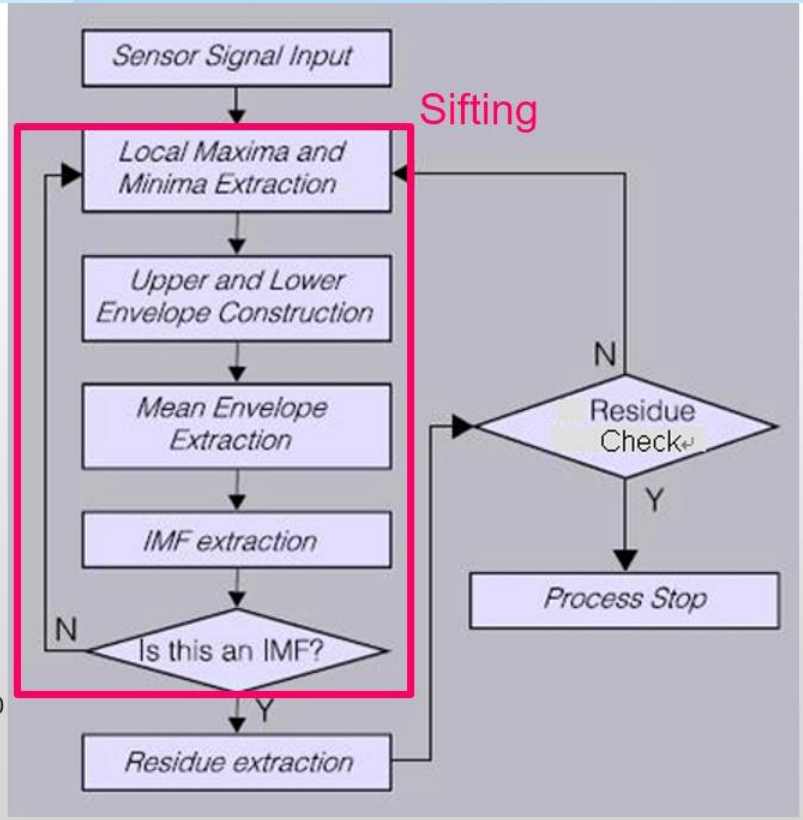
# EMD


sifting for IMF2, pass 1
proto-IMF
envelopes
envelope mean
3
2.5
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120

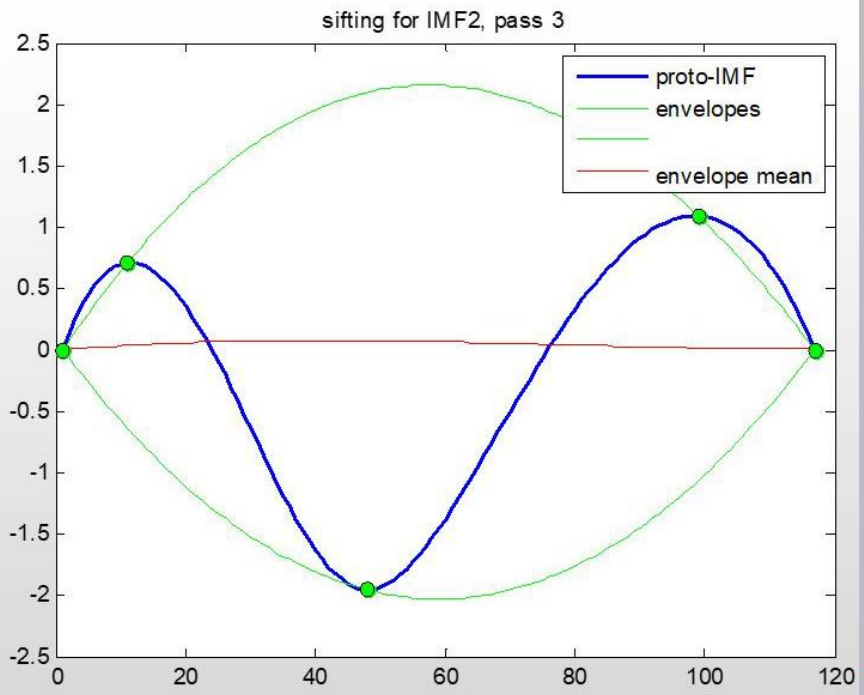

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

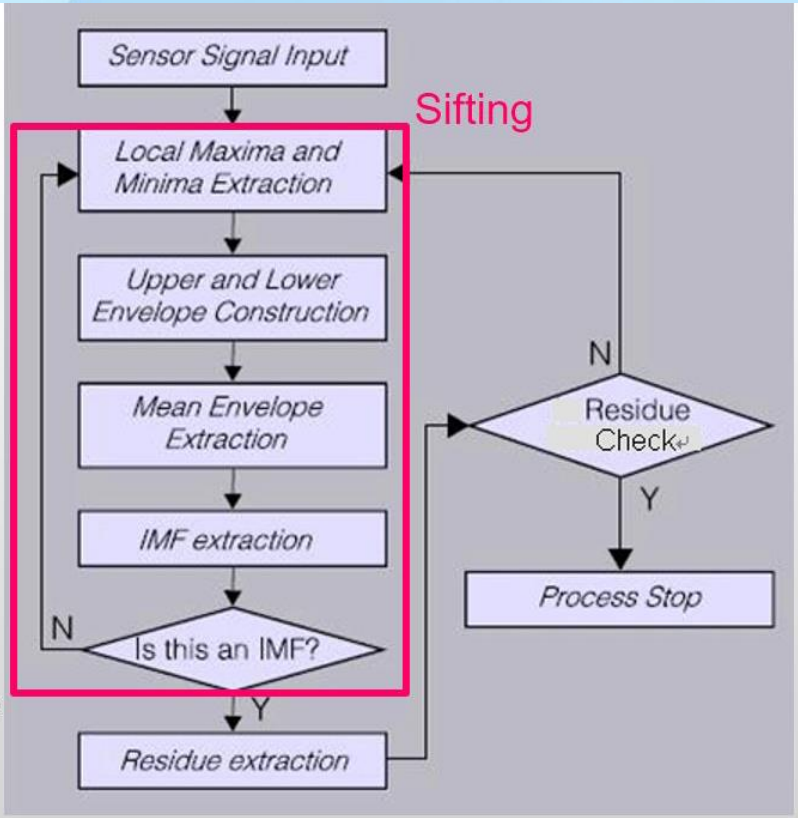
# EMD


sifting for IMF2, pass 2
proto-IMF
envelopes
envelope mean
2.5
2
1.5
1
0.5
0
-0.5
-1
-1.5
-2
0
20
40
60
80
100
120

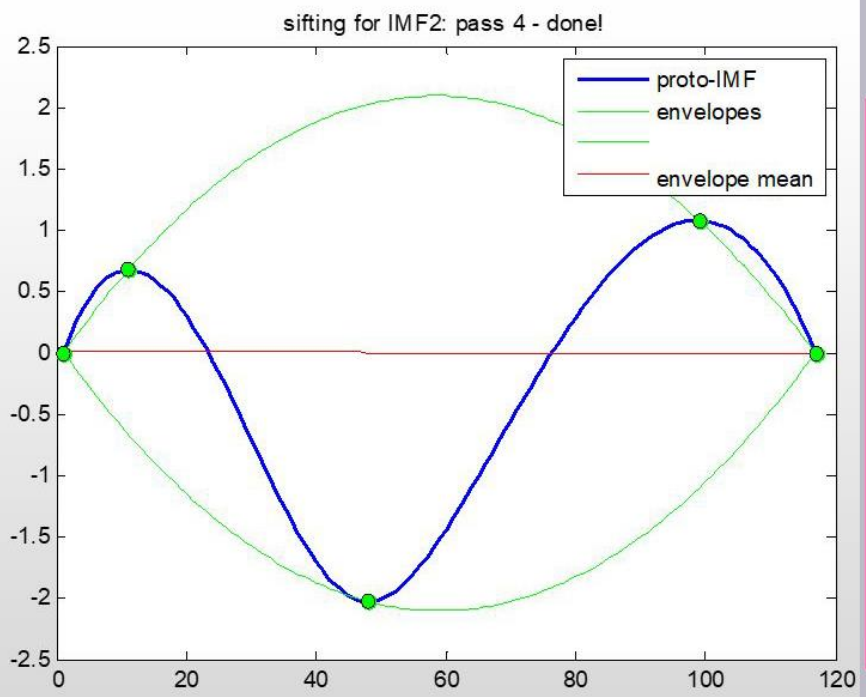

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

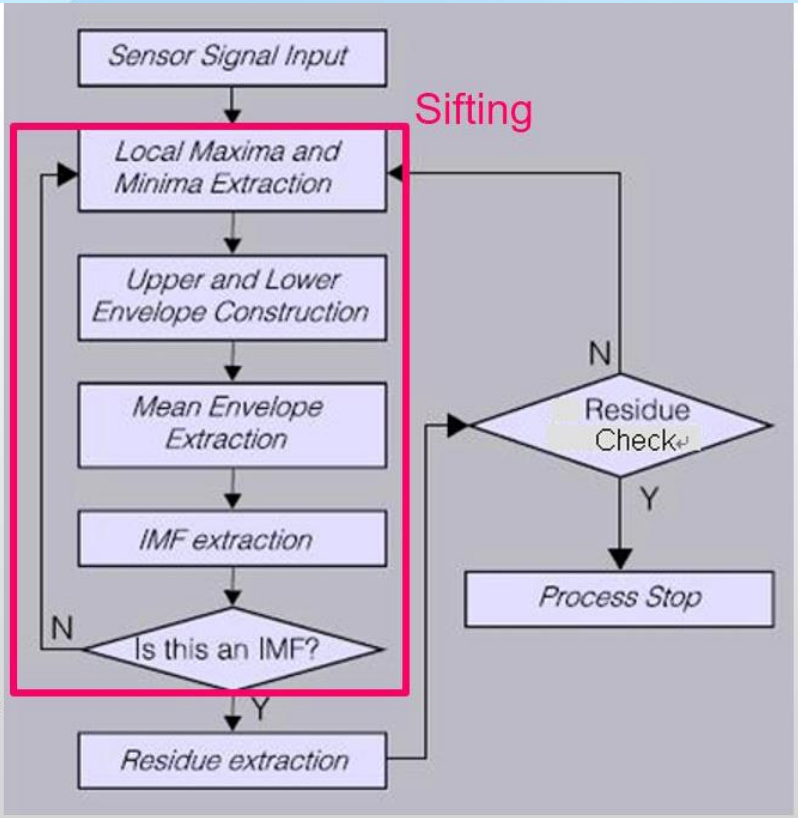
# EMD


sifting for IMF2, pass 3
proto-IMF
envelopes
envelope mean
2.5
2
1.5
1
0.5
0
-0.5
-1
-1.5
-2
-2.5
0
20
40
60
80
100
120

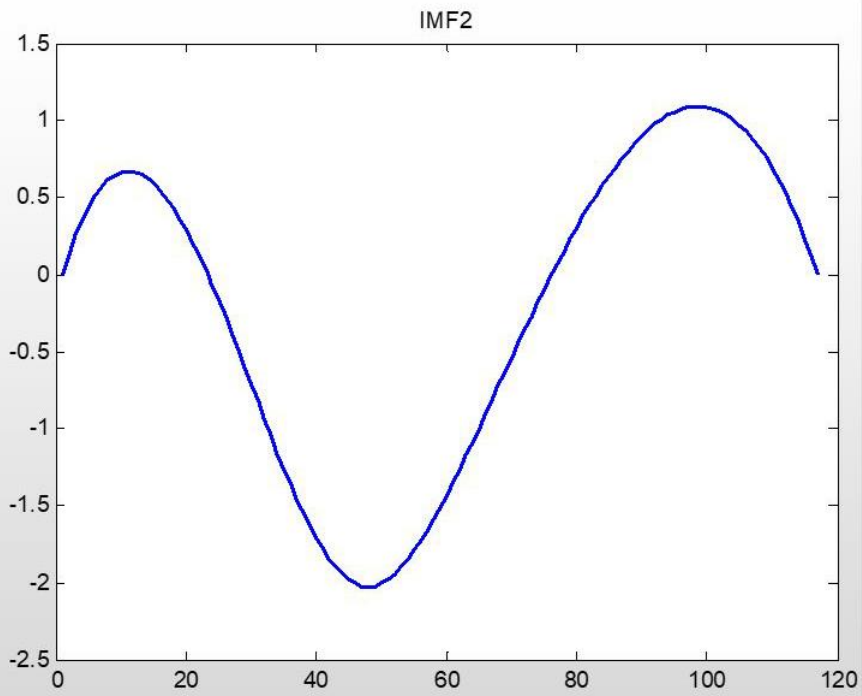

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
N
Is this an IMF?
Y
Residue extraction
N
Residue Check
Y
Process Stop

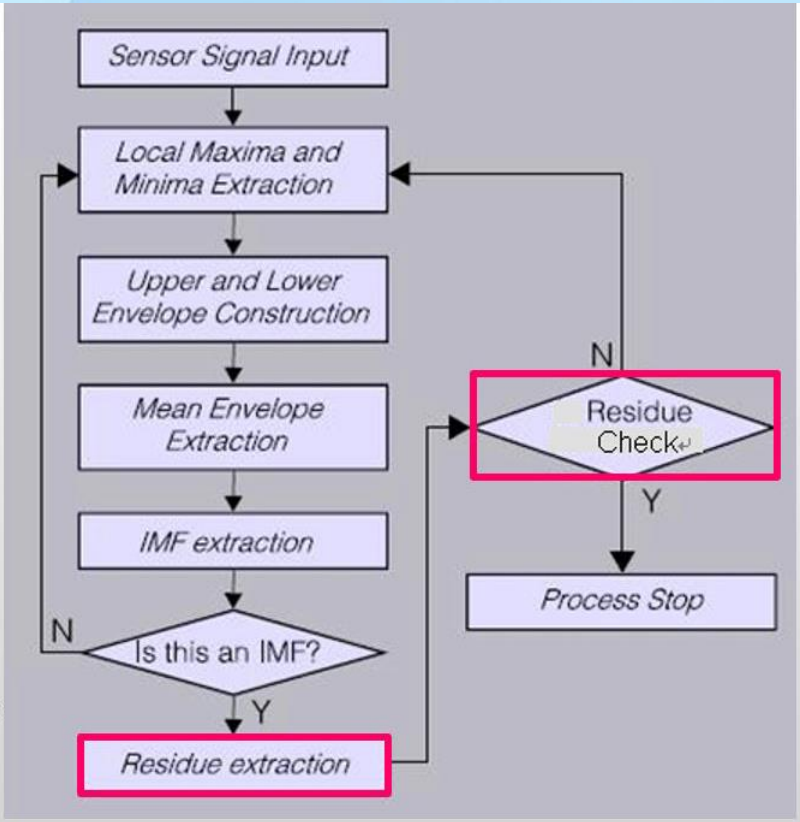
# EMD


sifting for IMF2: pass 4 - done!
proto-IMF
envelopes
envelope mean
2.5
2
1.5
1
0.5
0
-0.5
-1
-1.5
-2
-2.5
0
20
40
60
80
100
120

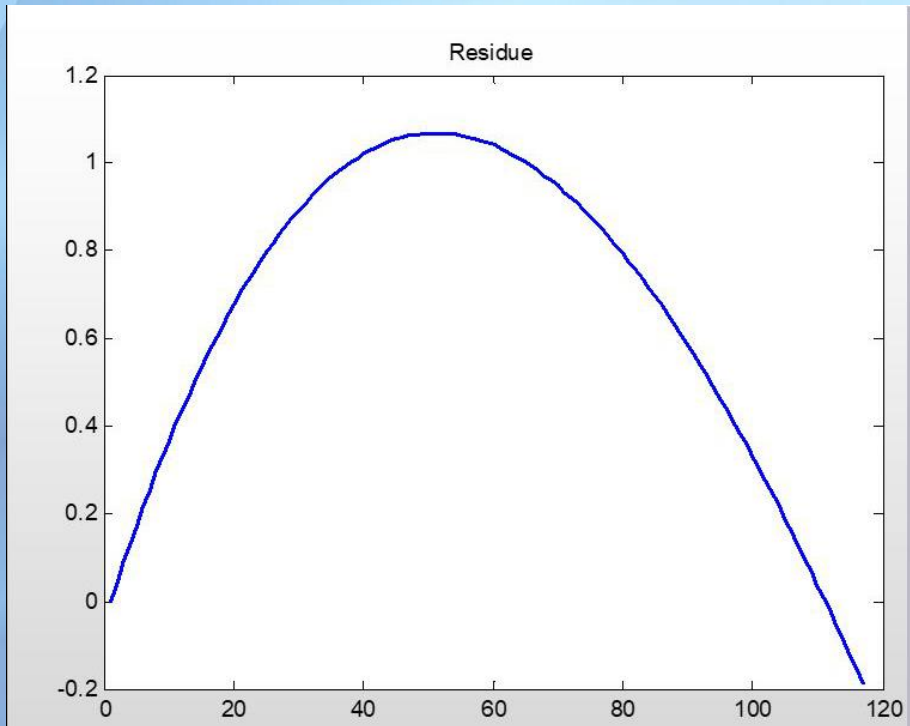

Sensor Signal Input
Sifting
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

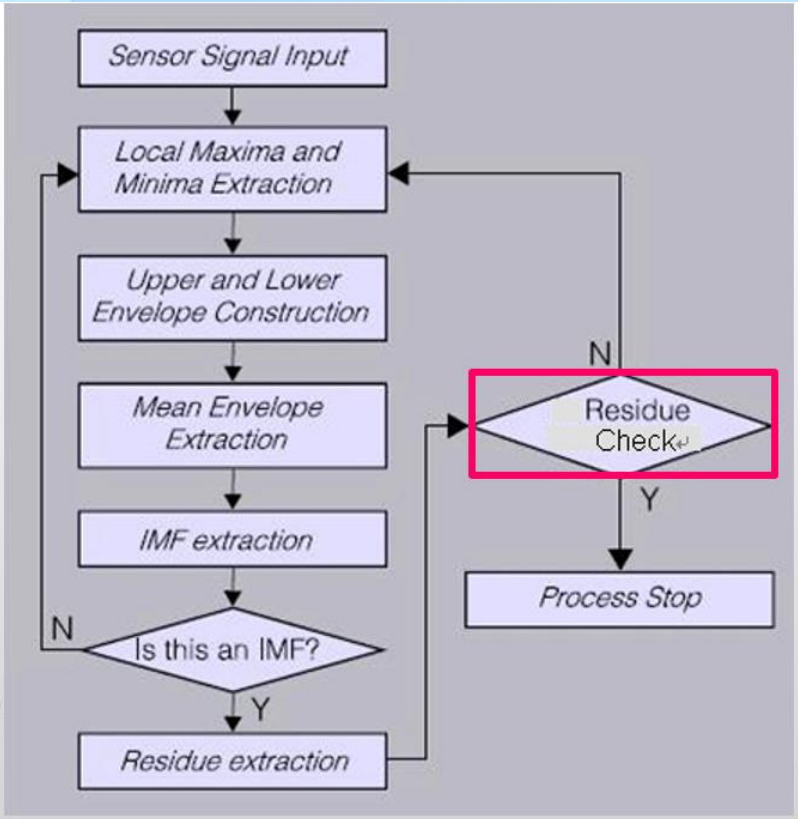
# EMD


IMF2
1.5
1
0.5
0
-0.5
-1
-1.5
-2
-2.5
0
20
40
60
80
100
120

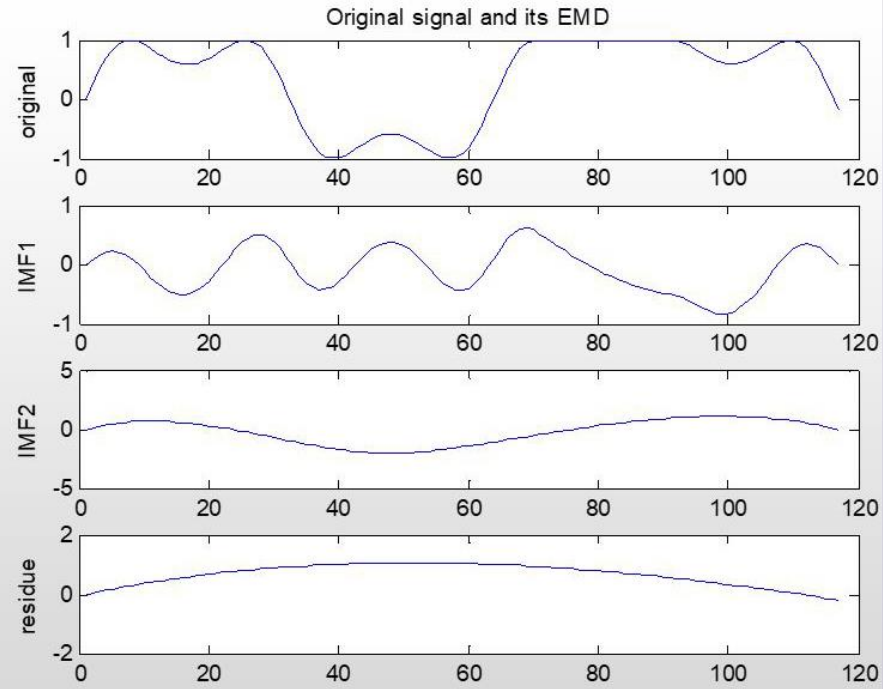

Sensor Signal Input
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

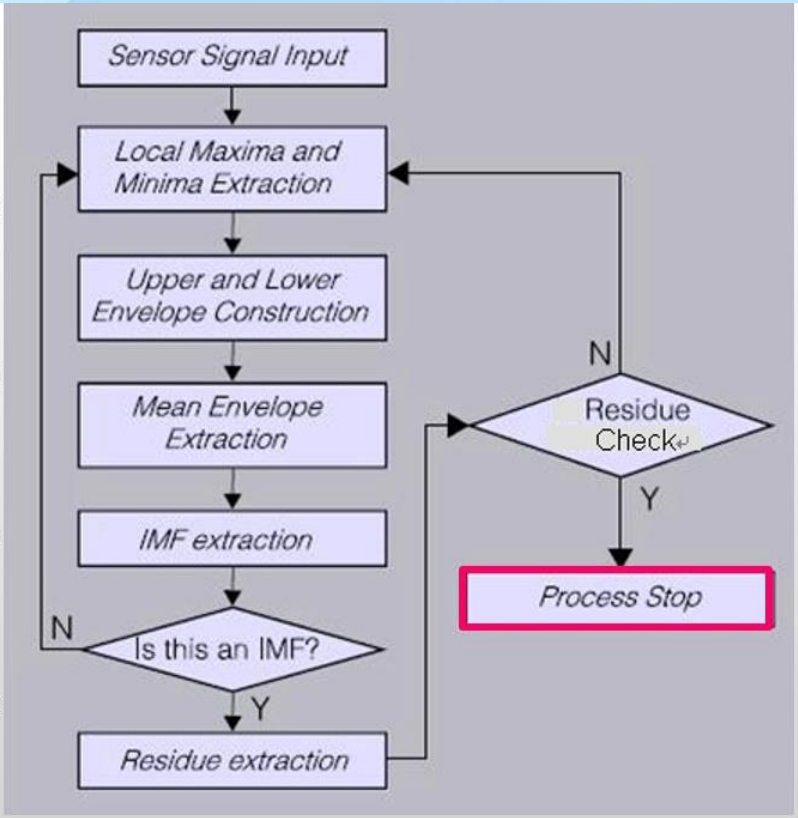
# EMD


Residue
1.2
1
0.8
0.6
0.4
0.2
0
-0.2
0
20
40
60
80
100
120


Sensor Signal Input
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

# EMD


Original signal and its EMD
original
IMF1
IMF2
residue
0
20
40
60
80
100
120


Sensor Signal Input
Local Maxima and Minima Extraction
Upper and Lower Envelope Construction
Mean Envelope Extraction
IMF extraction
Is this an IMF?
N
Y
Residue extraction
Residue Check
N
Y
Process Stop

# EEMD

- از آنجایی که هیچ مبنای نظری برای EMD وجود ندارد، به توجیه تئوری اثر مخلوط کردن حالت و پایان دادن آن بسیار دشوار است.
- برای حل مشکل مخلوط حالت در EMD، دسته بندی حالت تجربی حالت EEMD توسط Wu و Huang ارائه شده است، که مولفه های واقعی IMF را به عنوان میانگین مجموعه ای از آزمایشات تعریف می کند.

# EEMD

- The EEMD Technique (Lei et al., 2009)
- مرحله اول: مقدار ابتدایی نمونه ها M در نظر گرفته و دامنه نویز سفید اضافه شده را $m = 1$ بگذارید

– الف) مجموعه از نویزهای سفید را به سیگنال بررسی شده اضافه کنید،

$$x_m(t) = x(t) + n_m(t)$$

که در آن m شماره سری نویز اضافه شده با سیگنال متناسب آن است.

– ب) سیگنال نویزی $x_m$ را با استفاده از روش EMD به p تا IMF تقسیم کنید به صورتی که $C_{im}$ نشانگر i امین IMF از m امین سری بوده و p شماره IMF ها باشد.

# EEMD

ج- اگر $m < M$ باشد در این صورت به مرحله (الف) رفته و $m=m+1$ در نظر بگیرید. مرحله (الف) و (ب) را در حالی که در هر بار نویز متفاوتی به آن اضافه می شود، تکرار کنید.

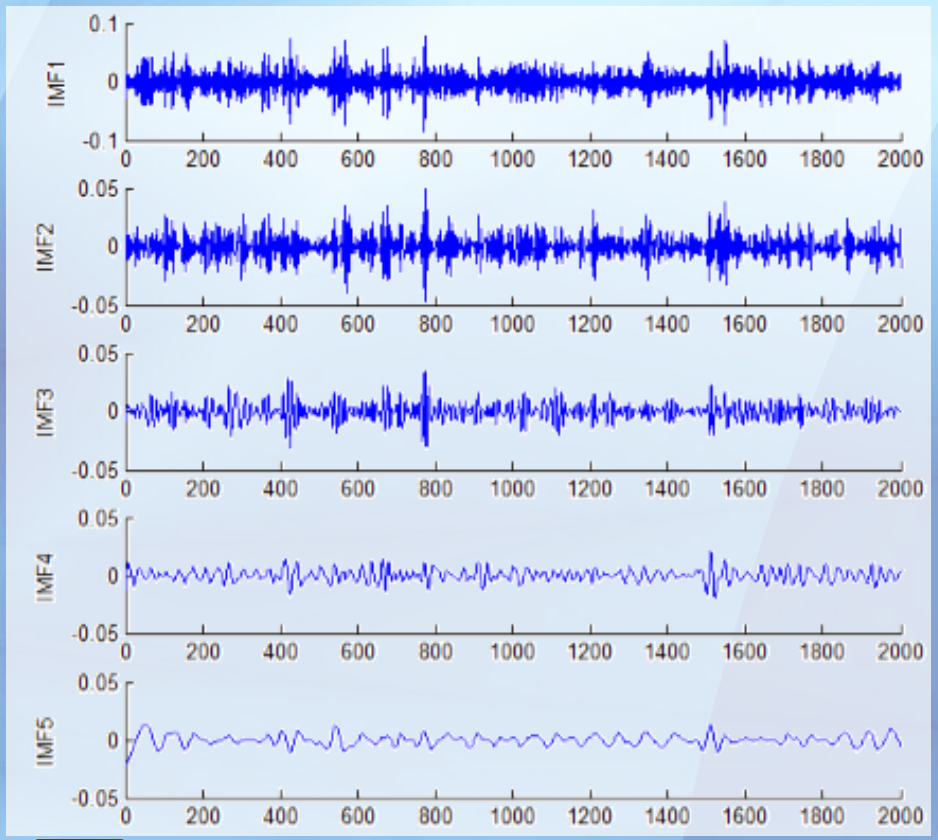
- مرحله دوم: مقدار میانگین نمونه های $a_i$ را برای M امین آزمایش برای هر IMF حساب کنید:

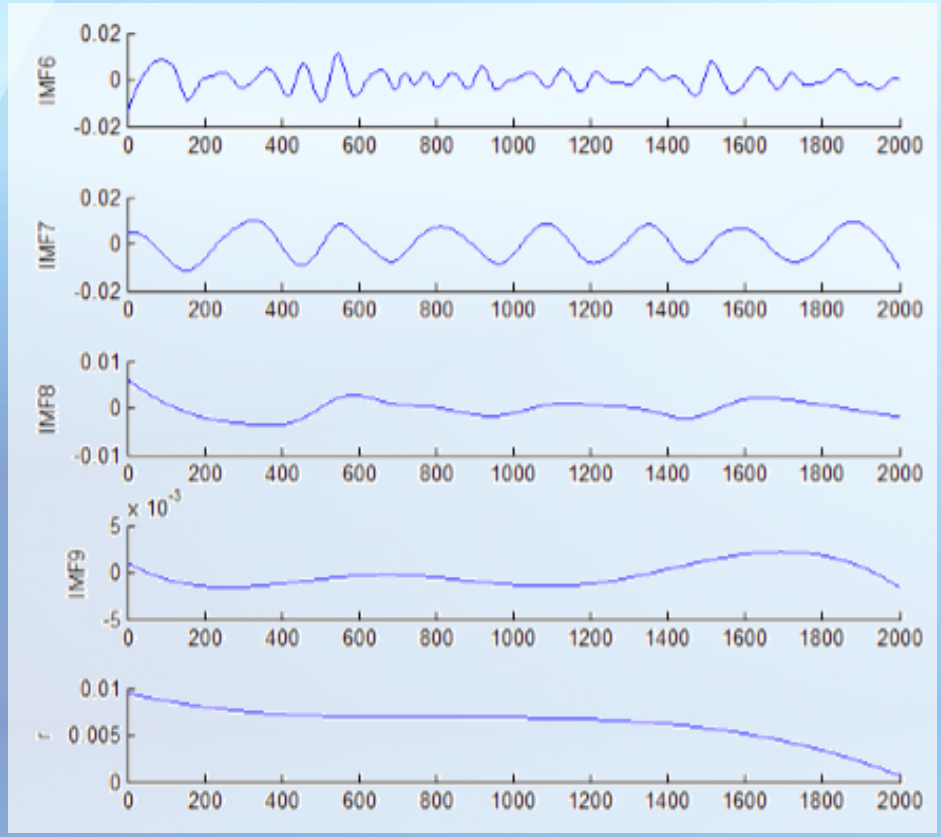
$$a_i = \frac{1}{M}\sum_{m=1}^{M} c_{i,m} \quad , i = 1, 2, \ldots, I, m = 1, 2, \ldots, M$$

- مرحله سوم: مقدار متوسط $a_i$ را برای i=1,2,…,p هر p امین IMF تا آخرین IMF تکرار کنید.

# EEMD

- نمونه از پردازش سیگنال با EEMD برای عیب یابی ماشین دوار



# EEMD

- امکان تعریف feature های مختلف برای هر یک از IMF ها فراهم خواهد شد
- فضای feature بسیار بزرگ است.

فصل پنجم

# روش های کلاسه بندی عیب

# کلاسه بندی

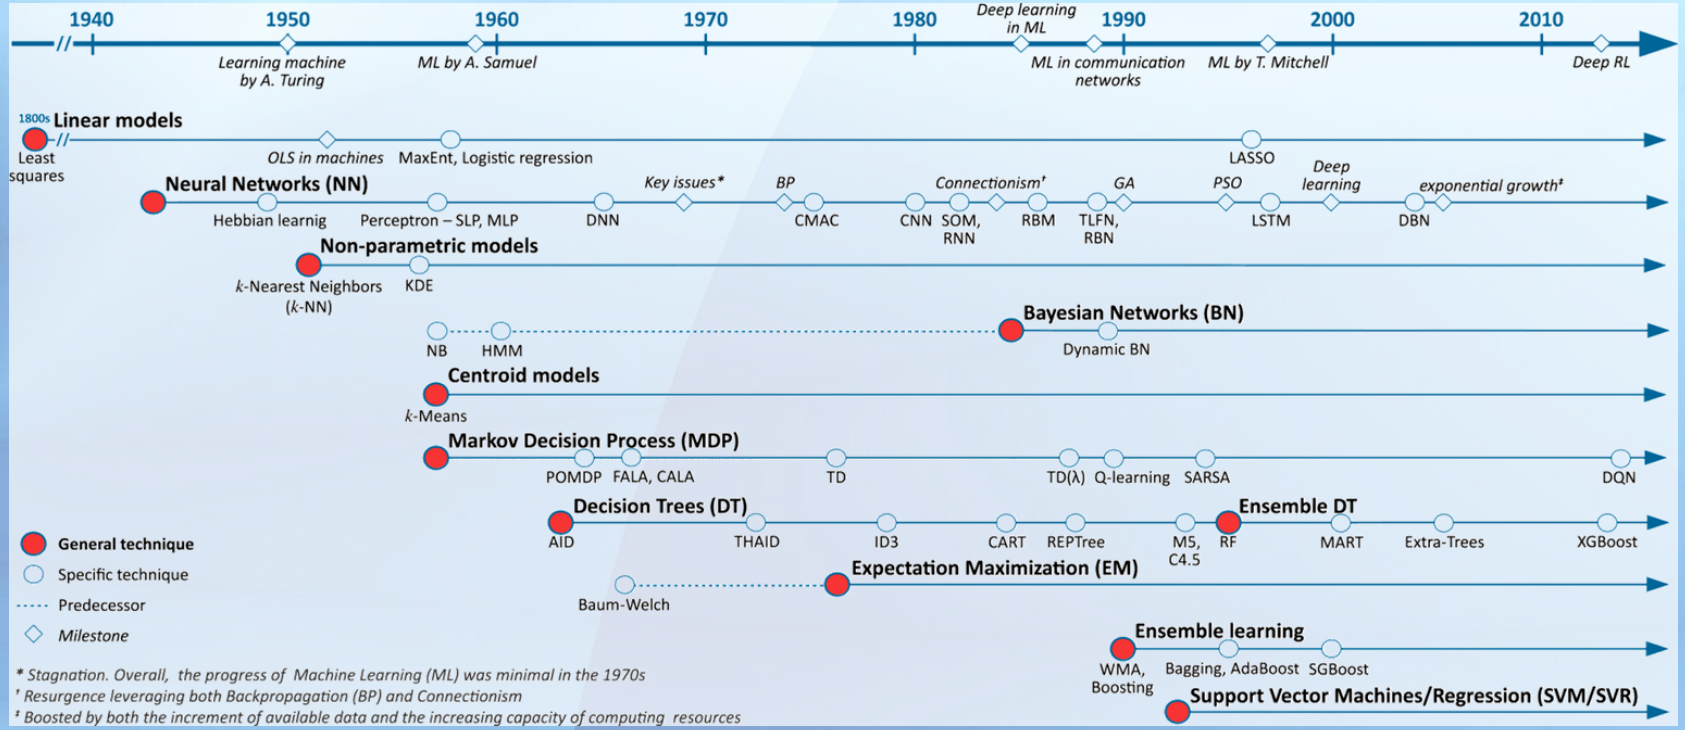
- کلاسه بندی یک روش داده کاوی (یادگیری ماشین) است که برای پیش بینی عضویت گروه برای نمونه های داده استفاده می شود.

- یادگیری ماشین یک علم بین رشته ای وسیع بر مبنای مفاهیم علوم رایانه، ریاضیات، آمار، علوم شناختی، مهندسی، نظریه بهینه سازی و... است.

- کاربردهای متفاوتی برای یادگیری ماشین وجود دارد، با این وجود داده کاوی مهمترین کاربرد این نوع روش ها است.

# کلاسه بندی

- یادگیری ماشین تاریخچه بسیار طولانی دارد، اما توسعه کابردی آن به دهه ۱۹۴۰ به بعد باز می گردد:

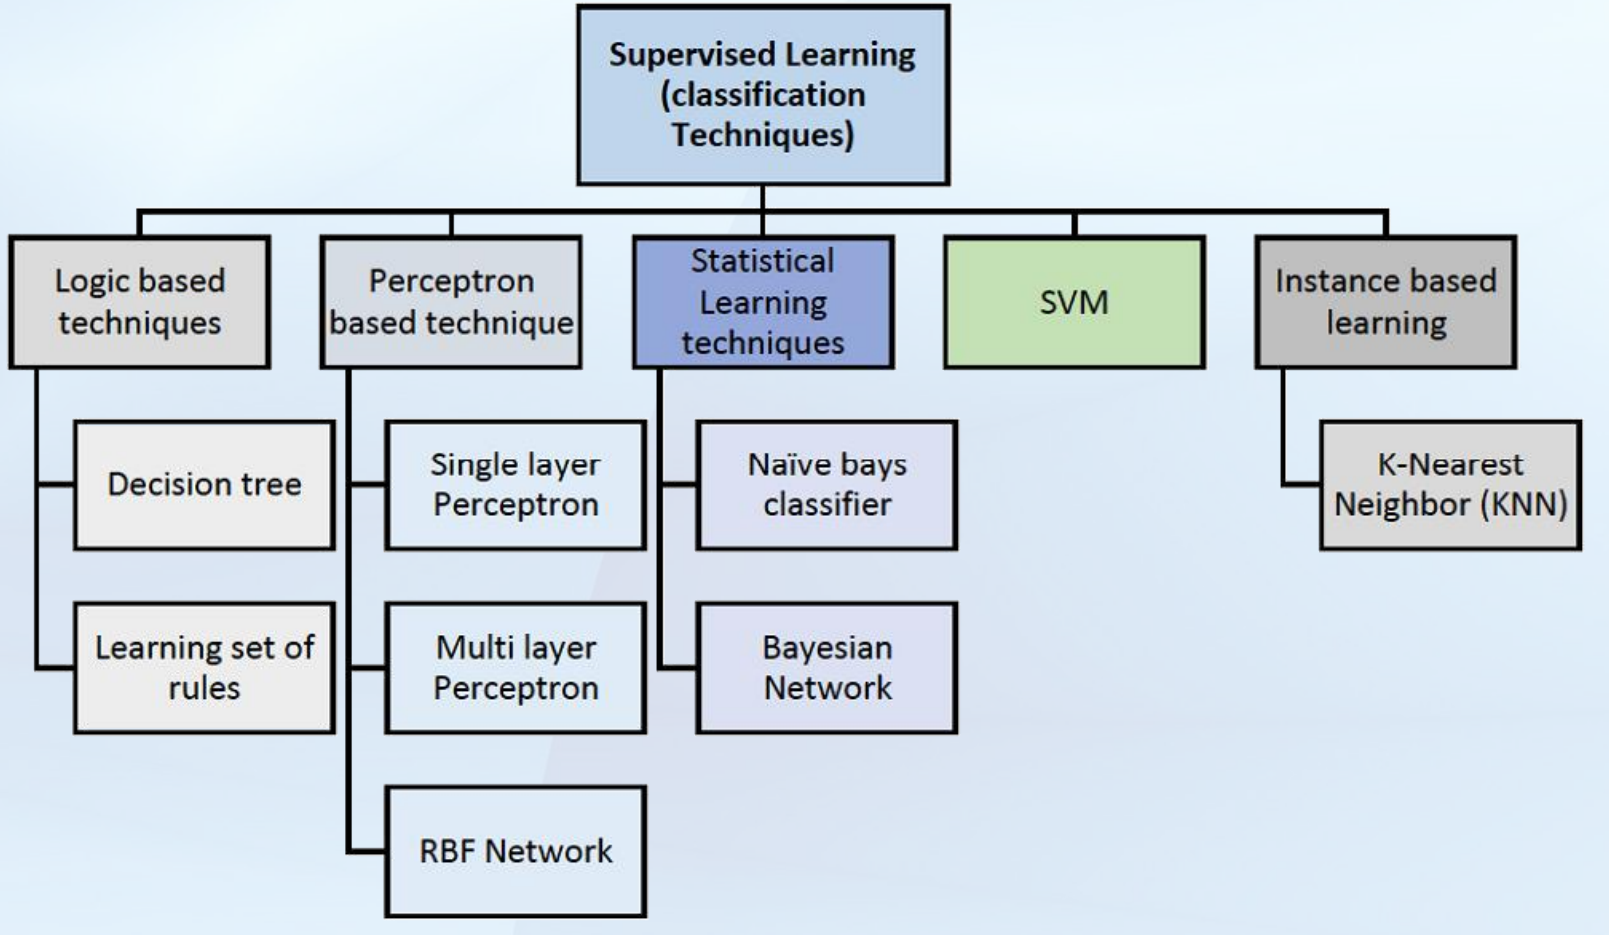


# کلاسه بندی

- یادگیری ماشین به دو دسته اصلی تقسیم می شود:
- یادگیری بدون نظارت:
  - این روش ها برای به دست آوردن نتیجه از مجموعه داده های ورودی بدون پاسخ برچسب زده شده استفاده می کنند،
  - خروجی مطلوب در دسترس نیست،
- یادگیری نظارتی:
  - این روش ها تلاش می کنند که رابطه میان صفات ورودی (متغیرهای مستقل) و یک ویژگی هدف (متغیر وابسته) را بیابند.
  - به دو کاربرد تقسیم می شوند: کلاسه بندی و رگرسیون

# کلاسه بندی

- روش های کلاسه بندی بر اساس یادگیری ماشین:



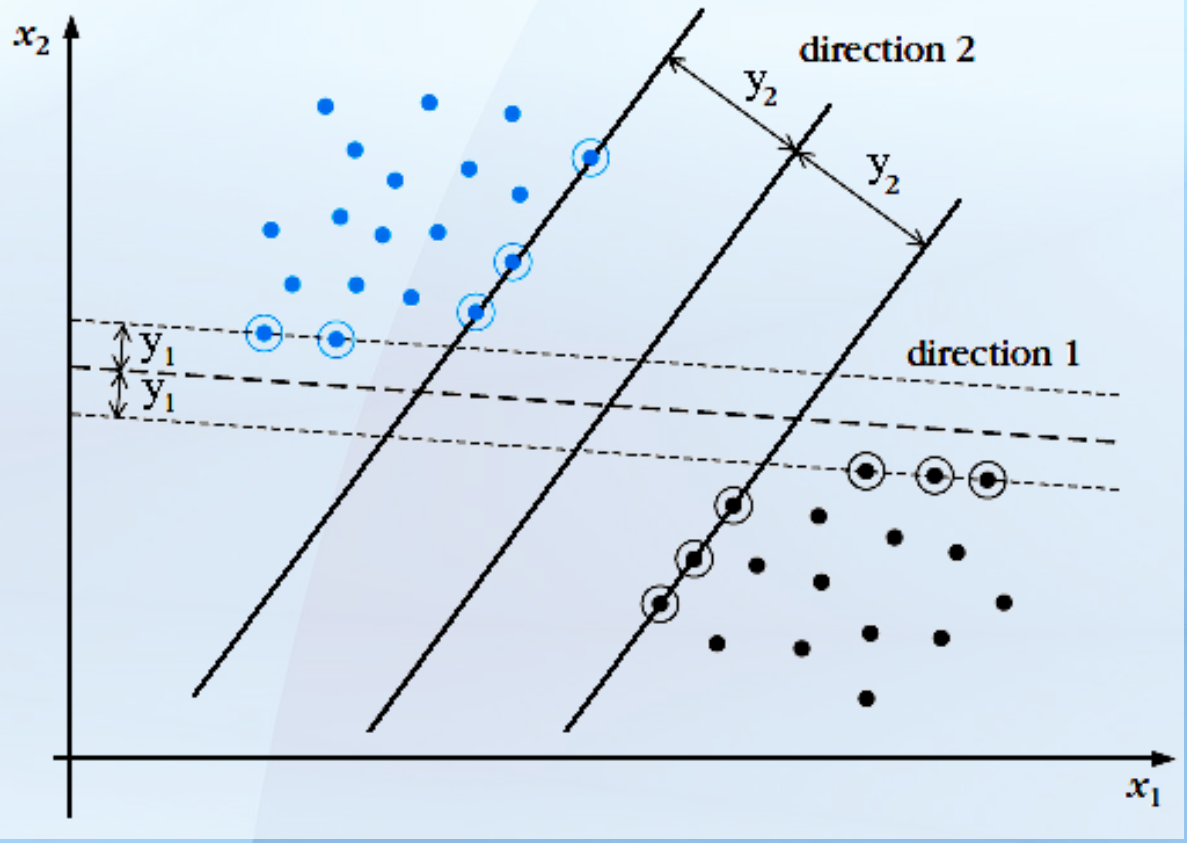
# ماشین بردار پشتیبان

- Support Vector Machine (SVM)

- ماشین بردار پشتیبان یک روش برای طراحی کلاسه بندی می‌باشد که کاربرد بسیار زیادی در عیب یابی دارد.
- در اساس، با توجه به مجموعه ای از نمونه های آموزشی که به دو دسته تقسیم شده اند، SVM باینری، برای طبقه بندی نمونه های جدید به یک دسته آموزش داده می شود.
- هدف طراحی یک ابرصفحه (hyperplane) خطی با حداکثر حاشیه نسبت به دو دسته می‌باشد

# ماشین بردار پشتیبان

- حداکثر حاشیه به جهت ابرصفحه وابسته است و هدف جستجوی جهتی با حداکثر حاشیه ممکن می‌باشد



# ماشین بردار پشتیبان

- SVM خطی
  - با فرض اینکه فقط $x_1$ و $x_2$ وجود داشته باشد، در حالت دو بعدی، معاده خط به شکل زیر خواهد شد:

$$w_1 x_1 + w_2 x_2 + b = 0$$

  - با در نظر گرفتن یک فضای M بعدی خواهیم داشت:

$$f(\boldsymbol{x}) = \boldsymbol{w}^{\mathrm{T}} \boldsymbol{x} + b = \sum_{j=1}^{M} w_j x_j + b = 0$$

$$\boldsymbol{x}_i \, (i = 1, 2, \cdots, M)$$

# ماشین بردار پشتیبان

- هر ابرصفحه با یک ضریب مقیاس تعیین می‌شود. برای مستقل نمودن نتیجه از این ضرایب، می‌توان بردار وزن و آستانه را طوری مقیاس نمود تا نزدیکترین نقاط در دو دسته یک و دو دارای $y_i$ به ترتیب ۱ و ۱- باشند.

$$f(\boldsymbol{x}_i) = 1 \text{ if } y_i = 1,$$

$$f(\boldsymbol{x}_i) = -1 \text{ if } y_i = -1,$$

یا

$$y_i f(\boldsymbol{x}_i) = y_i(\boldsymbol{w}^{\mathrm{T}}\boldsymbol{x}_i + b) \geq 1 \quad \text{for} \quad i = 1,2,\cdots M.$$

- این ابرصفحه ها، ابرصفحه های جداکننده و منطقه ای که توسط آنها محدود می شود، "حاشیه" نامیده می شوند.

# ماشین بردار پشتیبان

- از نظر هندسی، مرز $||w||^2$ می باشد. بنابراین معادله ابرصفحه جداساز بهینه با حل مساله بهینه سازی زیر قابل بدست آمدن است.

$$\text{minimize } \frac{1}{2}||w||^2$$

$$\text{subject to } y_i(w^T x_i + b) \geq 1, \quad i = 1, \cdots, M$$

- این مسئله را می توان با حل مسئله دوگانه لاگرانژ معادل با کمک شرط کاریوش-کوهن-تاکر KKT حل کرد.

# ماشین بردار پشتیبان

- شرایط KK :

$$\frac{\partial}{\partial \omega} L(\omega, \omega_0, \lambda) = 0 \qquad \frac{\partial}{\partial \omega_0} L(\omega, \omega_0, \lambda) = 0$$

$$\lambda_i \geq 0, \quad i = 1, 2, ..., N \qquad \lambda_i \left[ y_i \left( \omega^T x_i + \omega_0 \right) - 1 \right] = 0, \quad i = 1, 2, ..., N$$

- در روابط بالا، $\lambda_i$ ضریب لاگرانژ برای تابع لاگرانژ است

$$L(\omega, \omega_0, \lambda) = \frac{1}{2} \omega^T \omega - \sum_{i=1}^{N} \lambda_i \left[ y_i \left( \omega^T x_i + \omega_0 \right) - 1 \right]$$

- نهایتا با ترکیب این روابط داریم:

$$\omega = \sum_{i=1}^{N} \lambda_i y_i x_i \qquad \sum_{i=1}^{N} \lambda_i y_i = 0$$

# ماشین بردار پشتیبان

- ضرایب لاگرانژ می‌تواند صفر یا مثبت باشند.
- بنابراین، بردار پارامترها از حل بهینه یک ترکیب خطی از $N_S \leq N$ بردار ویژگی مرتبط با $\lambda_i \neq 0$ بدست می‌آید:

$$N_S \leq N$$

$$\lambda_i \neq 0$$

$$\omega = \sum_{i=1}^{N} \lambda_i y_i x_i$$

# ماشین بردار پشتیبان

- مساله بهینه سازی دو بعدی آن به صورت زیر بیان می شود.

$$\text{maximize } L(\boldsymbol{a}) = \sum_{i=1}^{M} a_i - \frac{1}{2} \sum_{i,j=0}^{M} a_i a_j y_i y_j \boldsymbol{x}_i^{\mathrm{T}} \cdot \boldsymbol{x}_j$$

$$\text{subject to } a_i \geq 0, \quad i = 1, \cdots, M, \quad \sum_{i=1}^{M} a_i y_i = 0.$$

- نکته مهم: ابرصفحه بهینه طبقه‌بند SVM یکتاست.
- با حل مسئله بهینه سازی بالا، ضرایب $a_i$ به دست می آید، که منجر به عملکرد تصمیم می شود.

$$f(\boldsymbol{x}) = \text{sign}\left( \sum_{i,j=1}^{\mathrm{M}} a_i y_i \boldsymbol{x}_i^T \cdot \boldsymbol{x}_j + b \right).$$

# ماشین بردار پشتیبان

- حاشیه نرم یا Soft Margin
  - ممکن است به دلیل وجود نویز در نمونه، ابرصفحه ای برای جدا کردن نمونه های دو کلاس وجود نداشته باشد.
  - در این صورت، SVM خطی موفق به یافتن جواب مناسبی نخواهد شد.
  - در این صورت روش حاشیه نرم راه حل مناسبی برای این مشکل است.
  - در این صورت، تابع بهینه سازی برای تضعیف قیود باید تغییر کند:

# ماشین بردار پشتیبان

- تابع بهینه سازی:

$$\text{minimize } \frac{1}{2}\|\boldsymbol{w}\|^2 + C\sum_{i=1}^{M}\xi_i$$

$$\text{subject to } \begin{cases} y_i(\boldsymbol{w}^{\mathrm{T}}\boldsymbol{x}_i + b) \geq 1 - \xi_i, & i = 1,\cdots,M \\ \xi_i \geq 0, & i = 1,\cdots,M \end{cases}$$

- در این تابع، $\xi_i$ فاصله بین حاشیه و نمونه $x_i$ در طرف اشتباه مرز را اندازه گیری می کند.
- از آنجایی که روش حاشیه نرم قادر به تضعیف اثر داده های خارج از محدوده یا outliers در SVM است، به طور گسترده ای در مشکلات طبقه بندی مورد استفاده قرار می گیرد

# ماشین بردار پشتیبان

- پارامتر $C$ یک ثابت مثبت برای کنترل شدت نسبی دو جمله رقیب می‌باشد.
- این پارامتر مصالحه ای بین خطای آموزش SVM و پیچیدگی حاشیه های تصمیم گیری را کنترل می کند.
- در صورتی که $C = \infty$ باشد، حاشیه نرم به حاشیه سخت (خطی) تبدیل می شود.

# ماشین بردار پشتیبان

- طبقه بندی غیرخطی:
  - زمانی که مجموعه ای از نمونه ها به صورت خطی قابل جدا شدن از هم نباشند، SVM می تواند برای حل مساله طبقه بندی غیرخطی نیز گسترش یابد.
  - با استفاده از توابع هسته یا Kernel، نمونه ها به یک فضای ویژگی با ابعاد بزرگتر که در آن طبقه بندی خطی امکان پذیر باشد، نگاشت می شود:

# ماشین بردار پشتیبان

- تابع هزینه غیرخطی به صورت زیر خواهد بود:

$$\text{maximize } L(\boldsymbol{a}) = \sum_{i=1}^{M} a_i - \frac{1}{2} \sum_{i,\, j=0}^{M} a_i a_j y_i y_j k(\boldsymbol{x}_j, \boldsymbol{x}_j)$$

$$\text{subject to} \begin{cases} 0 \le a_i \le C, \quad i = 1, \cdots, M \\ \sum_{i=1}^{M} a_i y_i = 0, \end{cases}$$

– نتیجه آنکه:

$$f(\boldsymbol{x}) = \text{sign}\left( \sum_{i,j=1}^{\text{M}} a_i y_i k(\boldsymbol{x}_i, \boldsymbol{x}_j) + b \right)$$

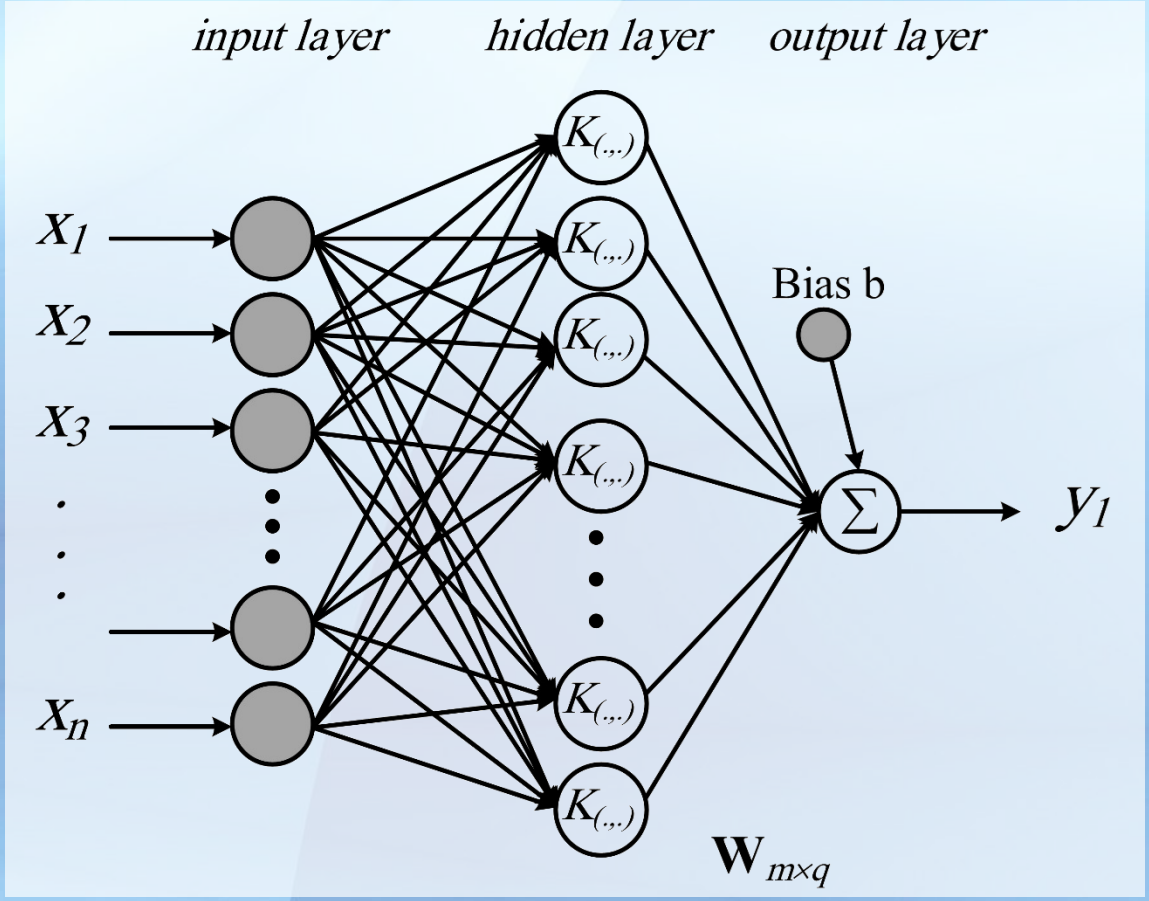
# ماشین بردار پشتیبان

- توابع مختلف برای Kernel به صورت زیر است:

| Kernel | $k(x, x_j)$ |
|---|---|
| Linear | $x^T x_j$ |
| Polynomial | $(\gamma x^T x_j + r)^d, \quad \gamma > 0$ |
| Gaussian RBF | $\exp(-\|\|x - x_j\|\|^2 / 2\gamma^2)$ |
| Hyperbolic tangent | $\tanh(\kappa x^T x_j + c)$ $\kappa > 0$ and $c < 0$ |

# ماشین بردار پشتیبان

- ساختار کلاسه بند غیرخطی SVM



# ماشین بردار پشتیبان مولتی کلاس

- یک مشکل SVM ، امکان مقایسه ۲ کلاس با هم است.
- در بسیاری از مسائل عیب یابی تعداد کلاس ها بیشتر از ۲ تا است.
- به عنوان مثال، کلاس های متعددی عیب در گیربکس ها و چرخدنده های مانند خوردگی، شکستگی، دندان پریدگی و غیره وجود دارد.

# ماشین بردار پشتیبان مولتی کلاس

- One-Against-All (OAA):
  - در این روش k تا SVM برای k کلاس مختلف ساخته می شود:

given $M$ training samples $(\boldsymbol{x}_1, y_1), \cdots, (\boldsymbol{x}_M, y_M)$ where $\boldsymbol{x}_j \in \Re^n$

$j = 1, \cdots M$ and $y_j \in \{1, \cdots, k\}$ is the label of $\boldsymbol{x}_j$, the $i$th SVM

$$\text{minimize } \frac{1}{2}\|\boldsymbol{w}^i\|^2 + C\sum_{i=1}^{M} \xi_j^i (\boldsymbol{w}^i)^{\mathrm{T}}$$

$$\text{subject to } (\boldsymbol{w}^i)^{\mathrm{T}} \phi(\boldsymbol{x}_j) + b^i \geq 1 - \xi_j^i \quad \text{if } y = i,$$

$$(\boldsymbol{w}^i)^{\mathrm{T}} \phi(\boldsymbol{x}_j) + b^i \leq 1 - \xi_j^i \quad \text{if } y \neq i,$$

$$\xi_j^i \geq 0, \qquad j = 1, \cdots, M,$$

# ماشین بردار پشتیبان مولتی کلاس

- One-Against-One (OAO):

– در این روش k(k-1)/2 تا SVM برای k کلاس مختلف ساخته می شود:

$$\text{minimize } \frac{1}{2}\|\boldsymbol{w}^{ij}\|^2 + C\sum_t \xi_t^{ij}(\boldsymbol{w}^{ij})^{\mathrm{T}}$$

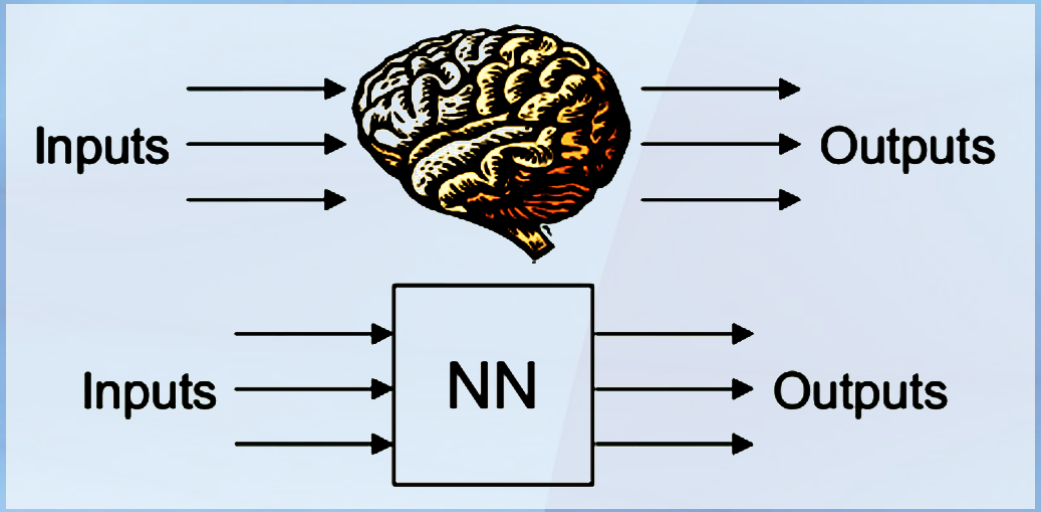
$$\text{subject to } (\boldsymbol{w}^{ij})^{\mathrm{T}}\phi(\boldsymbol{x}_t) + b^{ij} \geq 1 - \xi_t^{ij} \quad \text{if } y_t = i,$$

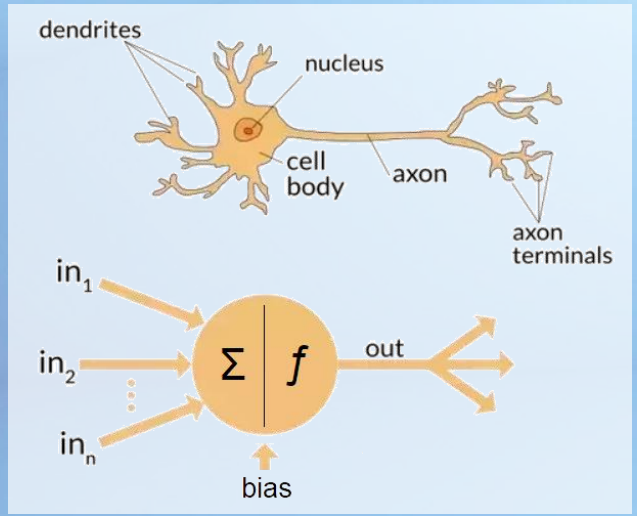
$$(\boldsymbol{w}^{ij})^{\mathrm{T}}\phi(\boldsymbol{x}_t) + b^{ij} \leq 1 - \xi_t^{ij} \quad \text{if } y_t \neq i,$$

$$\xi_t^{ij} \geq 0, \qquad t = 1, \cdots, M.$$

# شبکه های عصبی

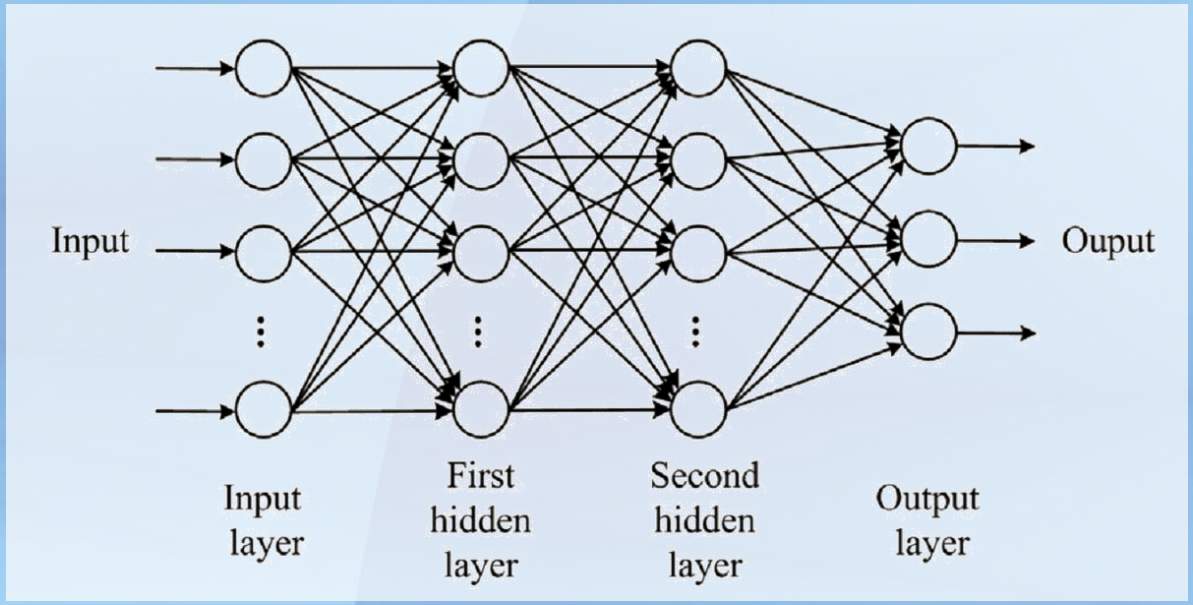
- مطالعه برروی شبکه‌های عصبی توسط مک کلاخ و پیتس در سال ۱۹۴۳ آغاز شد.
- شبکه‌های عصبی یک مدل بسیار ساده از مغز است و اساسا یک تابع تخمین زن یا approximator می باشد.



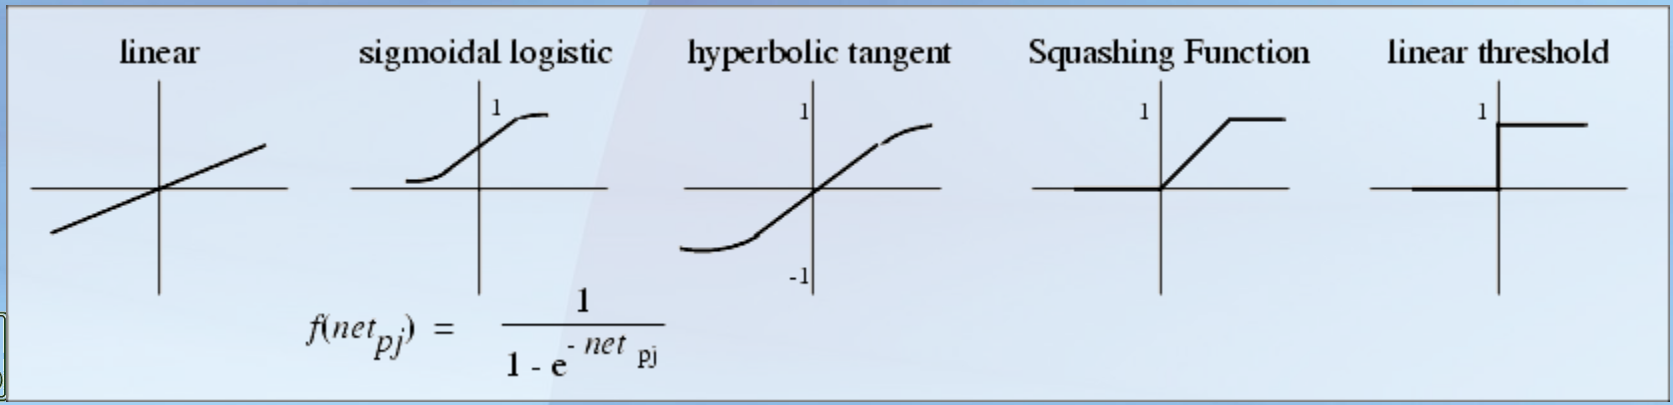
# شبکه های عصبی

- اساس شبکه های عصبی مصنوعی یا ANN یک پرسپترون چند لایه MLP است.
- این یک شبکه عصبی پیسخور متشکل از واحدهای نورون است که با ضرایب وزنی به هم متصل می شوند.



# شبکه های عصبی

- شبکه عصبی از چند لایه تشکیل شده است:
  - لایه ورودی: اتصال بین ورودی و شبکه عصبی (تابع خطی)
  - لایه خروجی: پاسخ خروجی از شبکه عصبی
  - لایه (های) میانی یا پنهان: مسولیت اصلی شناسایی و ارتباط بین لایه های ورودی و خروجی به عهده این لایه (ها) است.
    - تابع فعالساز گره یا activation function:



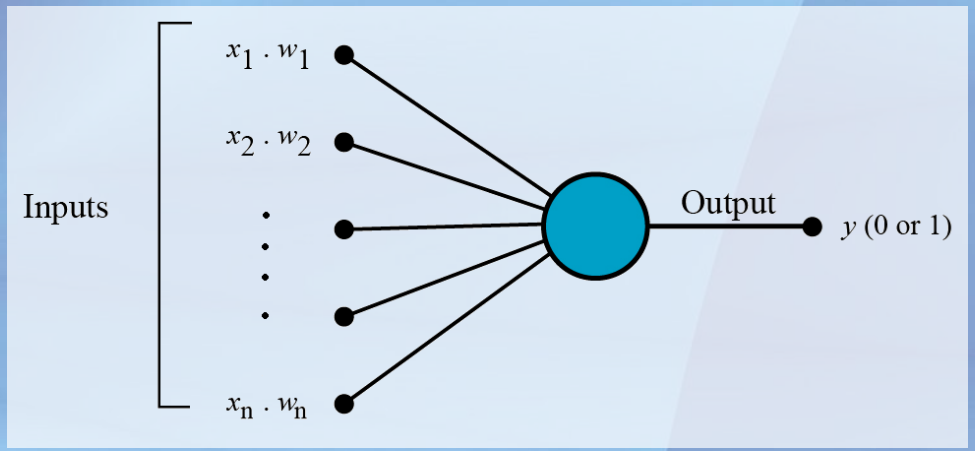
# شبکه های عصبی

- پرسپترون (Perceptron)
  - ساده ترین نوع ساختار شبکه عصبی است.
  - خروجی شبکه به صورت زیر است

$$y = f\left(\sum_{i=1}^{n} w_i x_i + b\right)$$

  - n تعداد ورودی های شبکه
  - خروجی به صورت ترشلد است:

$$f = \begin{cases} 1 & if \quad s > 0 \\ -1 & if \quad s \le 0 \end{cases}$$



# پس انتشار خطا

- Backpropagation

– محبوب ترین الگوریتم برای آموزش MLP، الگوریتم پس انتشار خطا است.

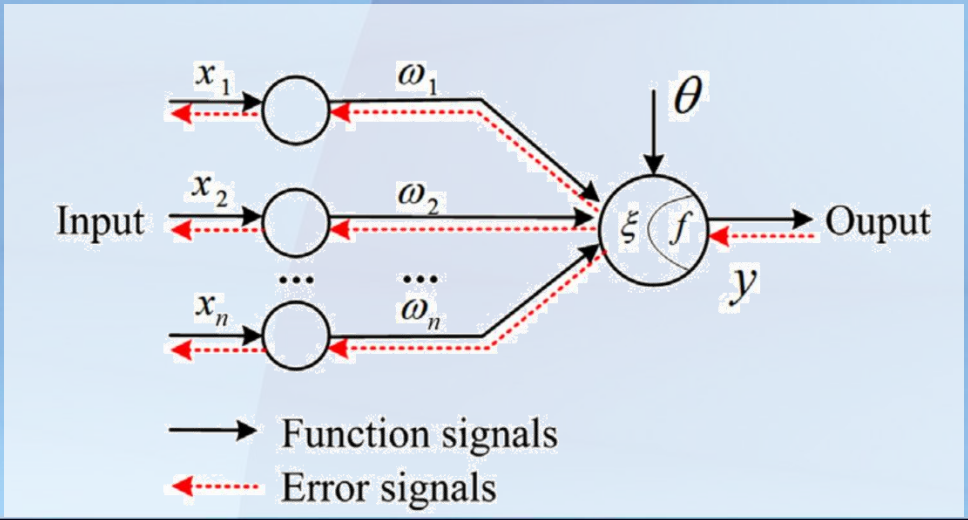
– اولین توصیف از الگوریتم پس انتشار خطا در رساله Werbos (1974) ارائه شده است.

– ایده اصلی الگوریتم پس انتشار خطا بر اساس به حداقل رساندن یک تابع خطای پیشنهادی حاصل از اختلاف بین خروجی های شبکه و خروجی های دلخواه با استفاده از تنظیم پارامترهای MLP یعنی ضرایب وزن و بیاس است.

# پس انتشار خطا

- روند آموزش دو مرحله دارد

❑ در مرحله پیشخور، پارامترهای MLP ثابت شده و داده های ورودی از طریق شبکه، لایه به لایه، تا زمانی که به آخرین لایه می رسد، منتشر می شود. بنابراین در این مرحله، تغییرات محدود به تعیین متغیرهای توابع فعال سازی و خروجی واحد در MLP محدود می شود.



# پس انتشار خطا

- در مرحله رو به عقب، سیگنال خطای حاصل از مقایسه نتیجه خروجی شبکه با برچسب مورد نظرش محاسبه می شود.
  - این سیگنال خطا برای اولین بار در لایه خروجی تولید و سپس از طریق لایه های شبکه پخش می شود.
  - جهت پخش رو به عقب انجام می شود. در این مرحله، تنظیمات پی در پی به وزن و بیاس MLP انجام می شود.
  - محاسبه این تنظیمات در لایه خروجی ساده است، اما برای لایه های متوسط چالش دارد.

# پس انتشار خطا

- در این روش با استفاده از Gradient descent سعی میشود تا مربع خطای بین خروجی های شبکه و تابع هدف حداقل شود. با تعریف خطا به شکل:

$$E_q = \frac{1}{2}\left(y_q - a_q^L\right)^2$$

- در یک فرآیند تکراری، پارامترها به روز می شود:

$$w_{i,j}^l = w_{i,j}^l - \alpha \frac{\partial E(w,b)}{\partial w_{i,j}^l}$$

$$b_i^l = b_i^l - \alpha \frac{\partial E(w,b)}{\partial b_i^l}$$

# پس انتشار خطا

- مشتق های جزیی برای محاسبه ضرایب لایه های داخلی به شکل زیر است

$$\frac{\partial E(w,b)}{\partial w_{i,j}^{l}} = \frac{\partial E(w,b)}{\partial z_{i}^{l}} \cdot \frac{\partial z_{i}^{l}}{\partial w_{i,j}^{l}}$$

$$\frac{\partial E(w,b)}{\partial b_{i}^{l}} = \frac{\partial E(w,b)}{\partial z_{i}^{l}} \cdot \frac{\partial z_{i}^{l}}{\partial b_{i}^{l}}$$

# پس انتشار خطا

- الگوریتم BP پیش از پایان می تواند به دفعات مختلف تکرار شود، لذا لازم است با در نظر گرفتن شرط پایان به ادامه حل الگوریتم خاتمه داد:
  - توقف بعد از تکرار به دفعات معین
  - توقف وقتی که خطا از یک مقدار تعیین شده کمتر شود.
  - توقف وقتی که خطا در مثالهای مجموعه تائید از قاعده خاصی پیروی نماید.
- در صورت کم بودن تعداد تکرارها، خطای مدلسازی وجود خواهد داشت و در صورت انجام تکرارهای زیاد مسئله Overfitting رخ خواهد داد.

# پس انتشار خطا

- جستجوی الگوریتم BP بر اساس gradient descent در فضای وزنها انجام می شود.
  - ممکن است در یک مینیمم محلی گیر بیافتد
  - در عمل بسیار موثر بوده است
- برای پرهیز از مینیمم محلی روشهای مختلفی وجود دارد:
  - افزودن ممنتم
  - استفاده از stochastic gradient descent
  - استفاده از شبکه های مختلف با مقادیر متفاوتی برای وزنهای اولیه

# پس انتشار خطا

- برای شتاب دادن به مکانیزم به هنگام سازی پارامترها می توان از ضریب ممنتوم استفاده کرد.
- میتوان قانون تغییر وزنها را طوری در نظر گرفت که تغییر وزن در تکرار n ام تا حدی به اندازه تغییر وزن در تکرار قبلی بستگی داشته باشد.

$$\Delta w_{i,j}(k) = \eta \Delta w_{i,j}(k-1) + \alpha \frac{\partial E(w,b)}{\partial b_i^l}$$

$$w_{i,j}^l(k) = w_{i,j}^l(k-1) - \Delta w_{i,j}(k)$$

# شبکه های عصبی تشخیص الگو

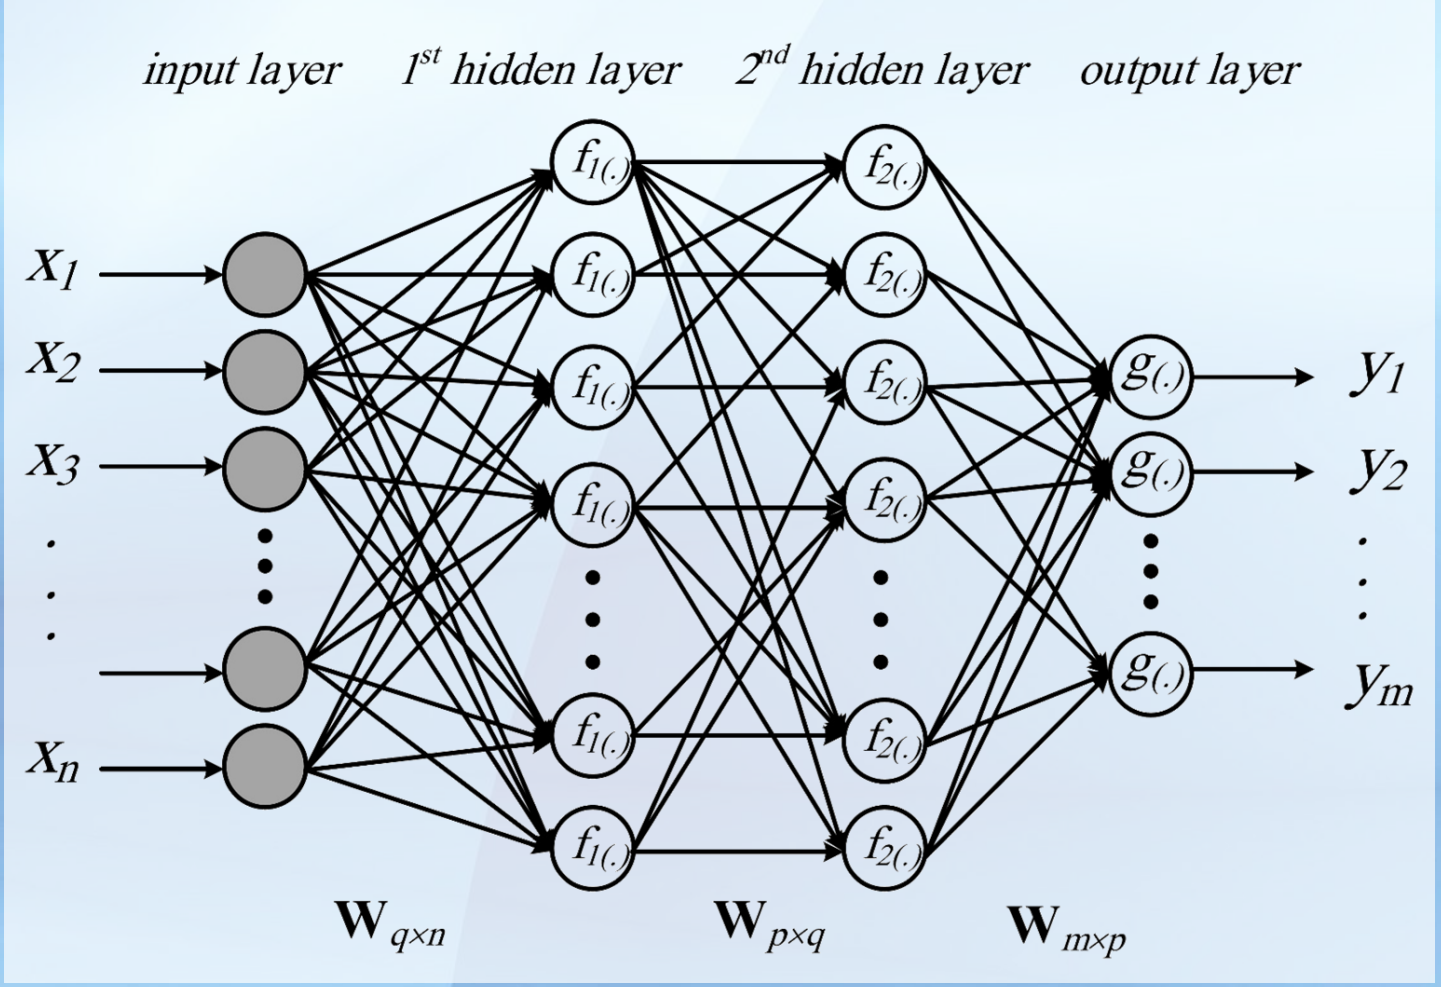
- Neural Networks Pattern Recognition (NNPR)
  - این نوع شبکه عصبی تفاوتی با شبکه های عصبی MLP ندارد.
  - تنها فرق آن در لایه خروجی است.
  - توابع آتشباری برای سه لایه مختلف یک شبک عصبی تشخیص الگو به صورت زیر است:

$$f_1^{\,j}(u) = \text{tansig}(u_j) = 2/\left(1+\exp\left(-2u_j\right)\right)-1 \quad , \quad j = 1,\ldots,q$$

$$f_2^{\,j}(u) = \text{tansig}(u_j) = 2/\left(1+\exp\left(-2u_j\right)\right)-1 \quad , \quad j = 1,\ldots,\text{p}$$

$$g^{\,j}(v) = \text{softmax}(v_j) = \exp\left(v_j\right)/\sum_{k=1}^{m}\exp\left(v_j\right) \quad , \quad j = 1,\ldots,m$$

# شبکه های عصبی تشخیص الگو



# سیستم های فازی

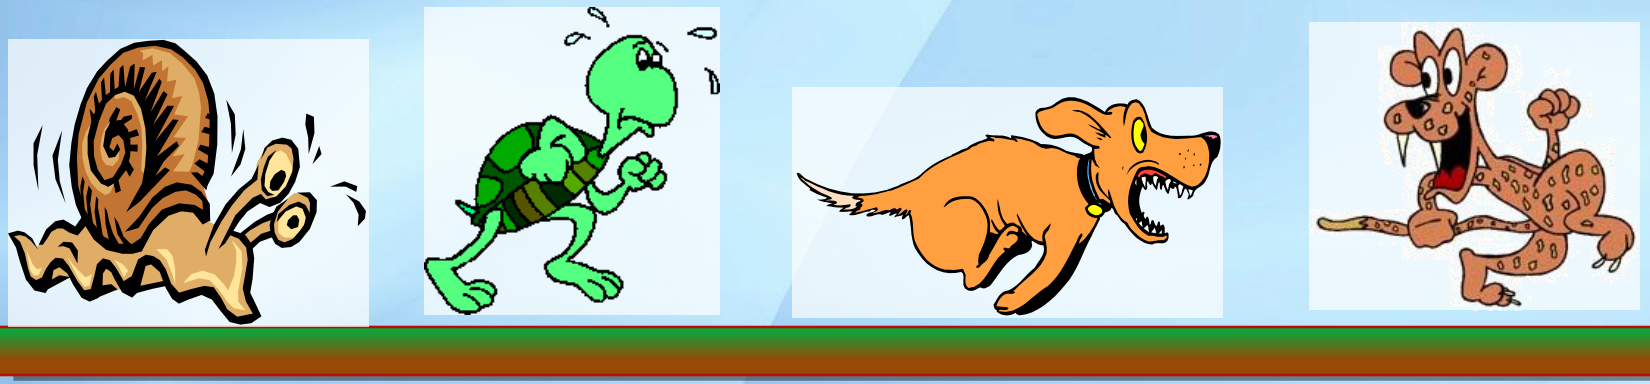
- سیستم های فازی به دلیل توانایی ویژه در یادگیری و استنتاج می تواند به دو شکل مختلف در فرآیند عیب یابی بکار گرفته شوند:
- سیستم های استنتاجی یا inference system
  - بر اساس قوانین فازی و اطلاعات فرد خبره می توان شرایط مختلف را استنتاج کرد← فازی نوع ممدانی Mamdani
- کلاسه بندی های فازی
  - داده های موجود از فضای نشانه ها و خطا در یادگیری ماشین مورد استفاده قرار گیرد ← فازی نوع ساجینو Sugeno

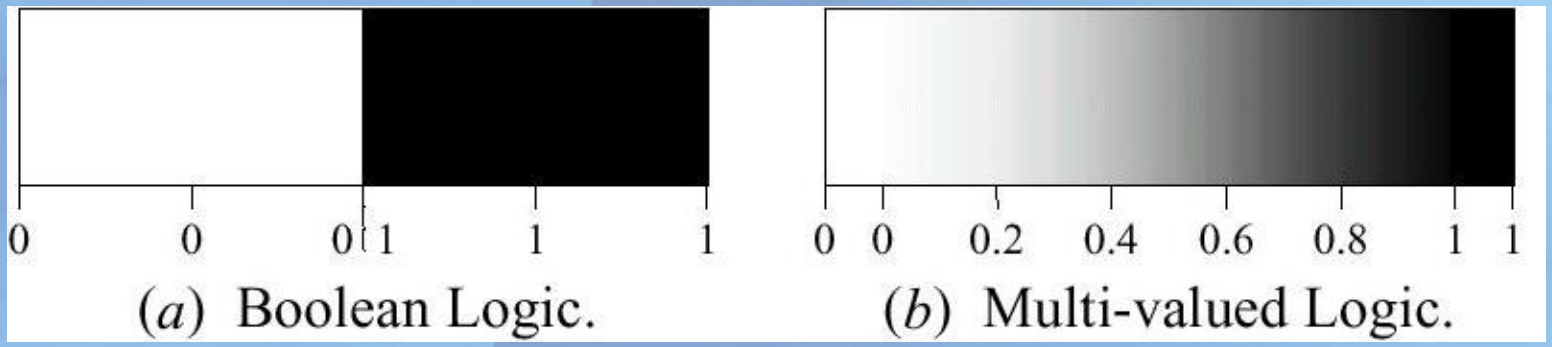
# Fuzzy vs. Crisp

- منطق فازی بر این اساس استوار است که هر چیز به صورت یک درجه بیان شود.

  - دما: خیلی سرد است
  - ارتفاع: او یک فرد بلند قد است.
  - سرعت:...

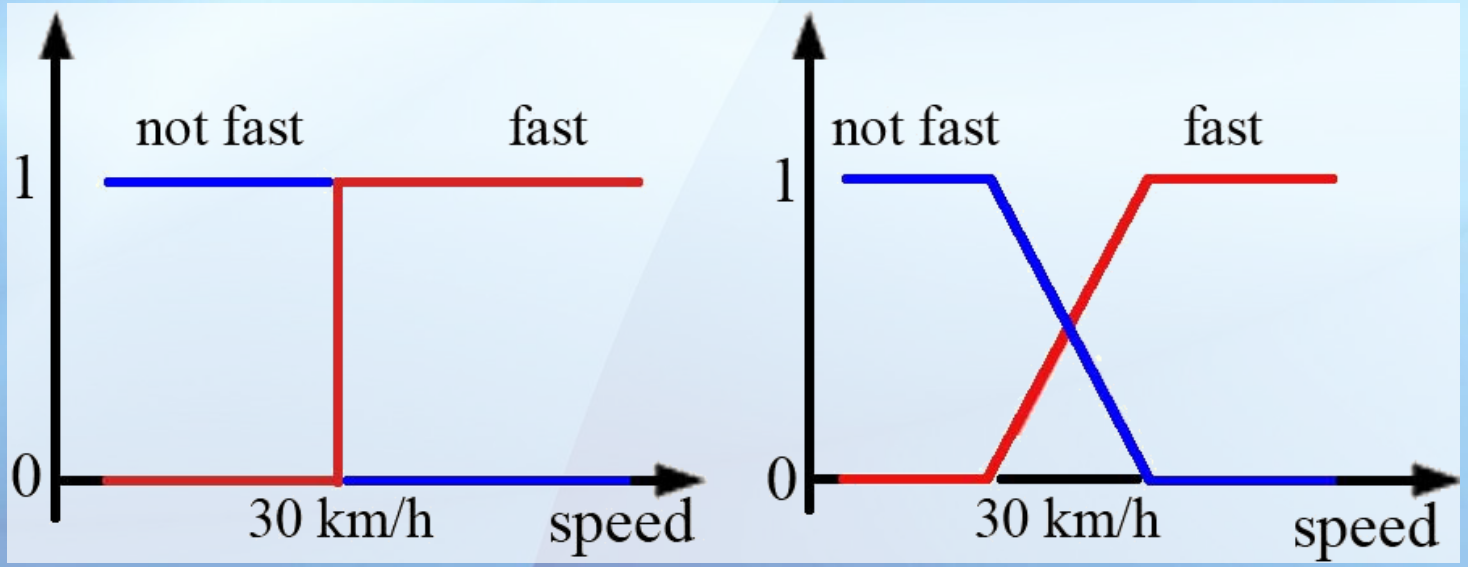
# Fuzzy vs. Crisp



# Fuzzy vs. Crisp

- توابع عضویت فازی



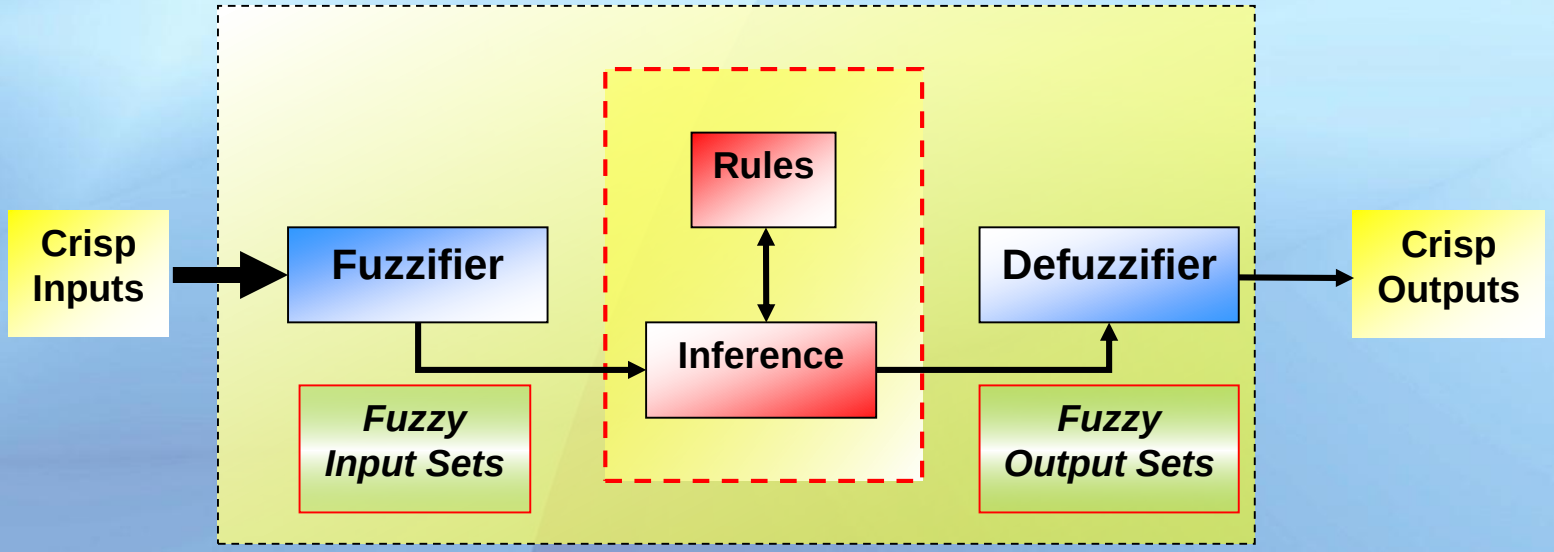

{0, 1}

[0, 1]

Grade of truth

# فرآیند استنتاج فازی

- ساختار یک سیستم استنتاج فازی به صورت زیر است




**Fuzzification:** Translate input into truth values
**Rule Evaluation:** Compute output truth values
**Defuzzification:** Transfer truth values into output

# فرآیند استنتاج فازی

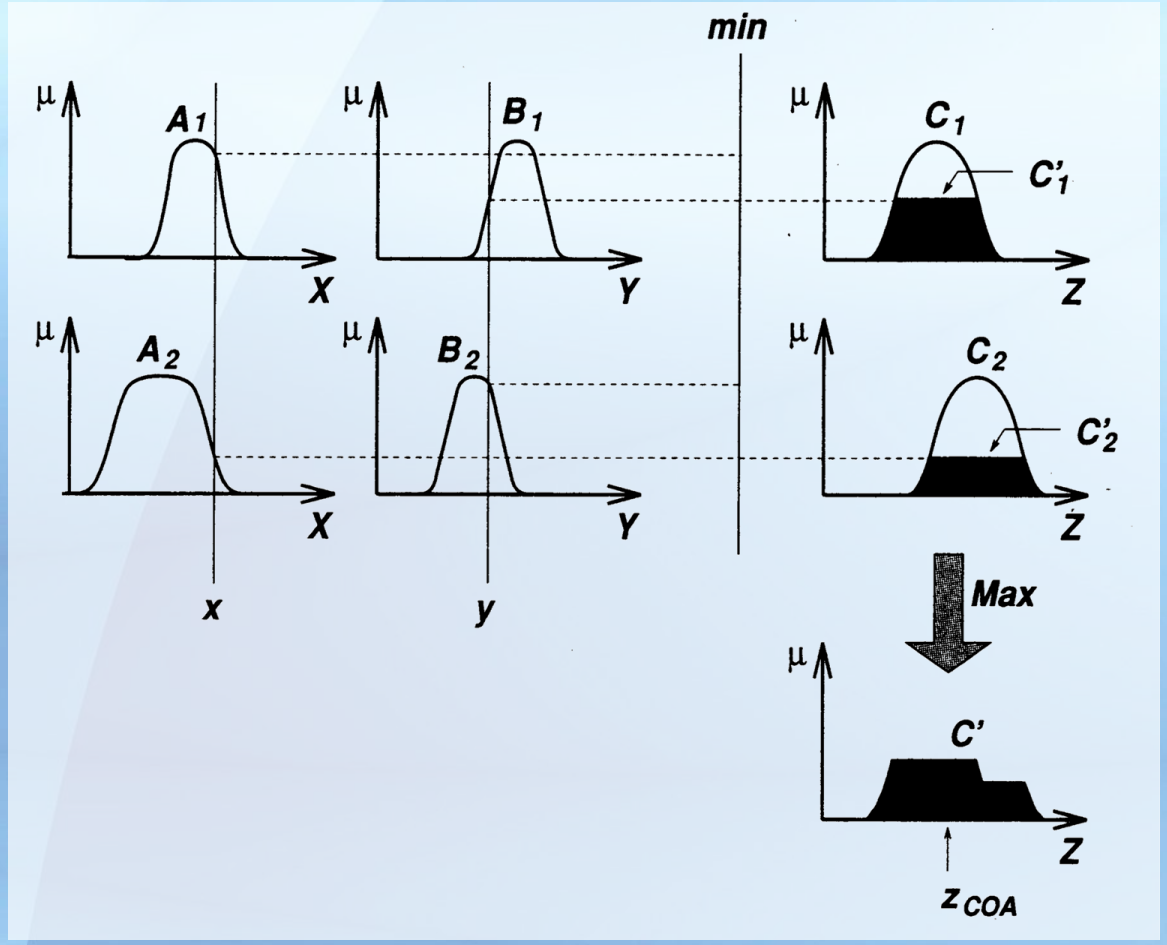
- یک قانون فازی به صورت یک جمله شرطی به شکل زیر بیان می شود:

IF $x$ is $A$ THEN $y$ is $B$

- ***if*** *(MF1)* ***and/or*** *(MF2) ….* ***then*** *(output MF).*

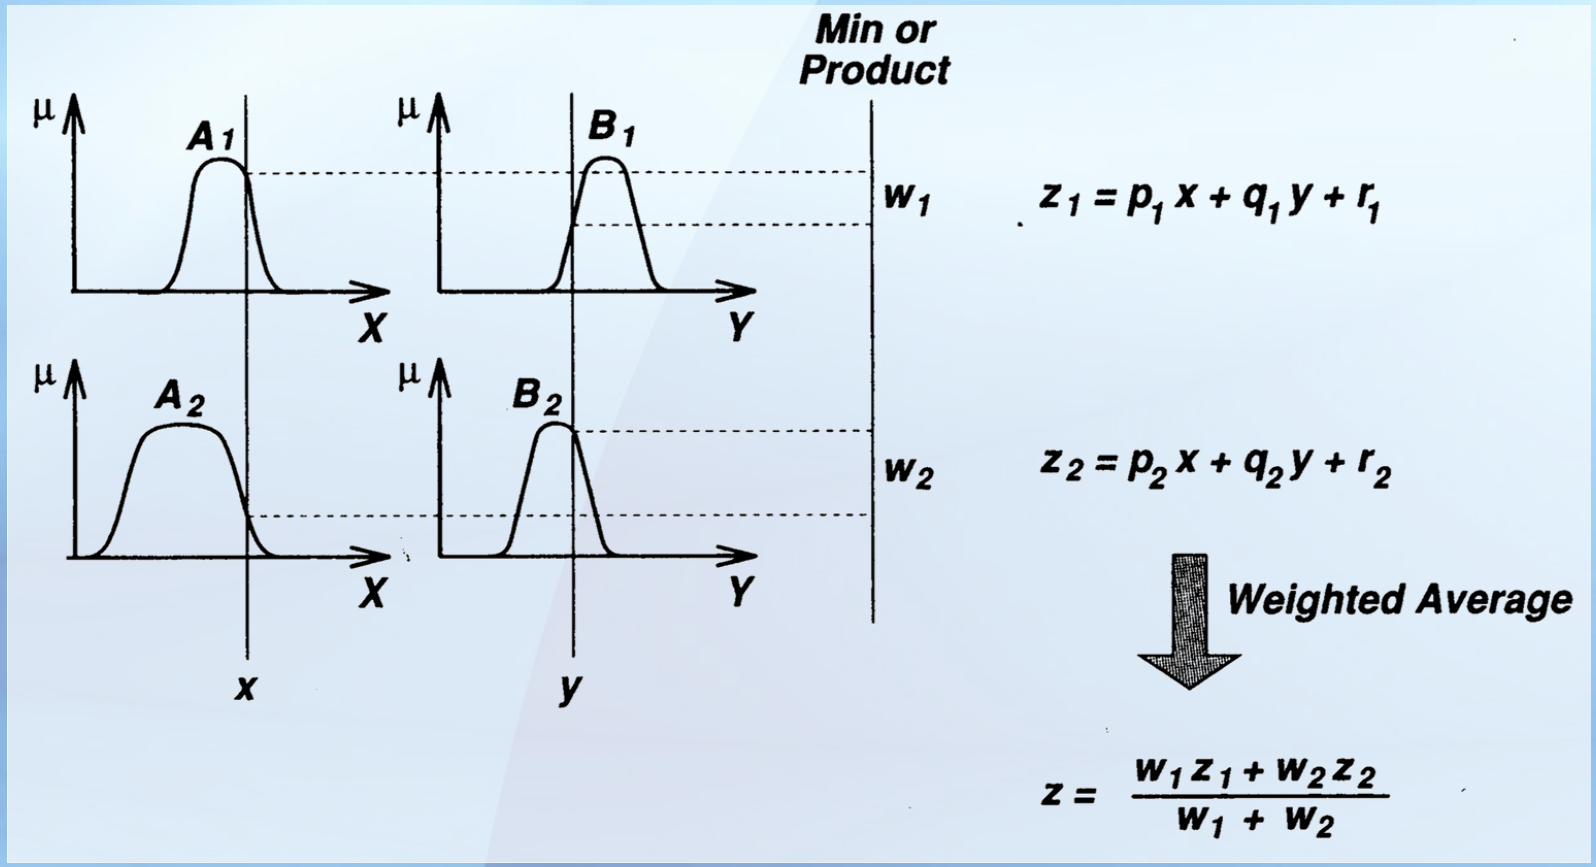
# سیستم استنتاج فازی: ممدانی

- 1st generation: Mamdani
  - Max-Min
  - Max- Product



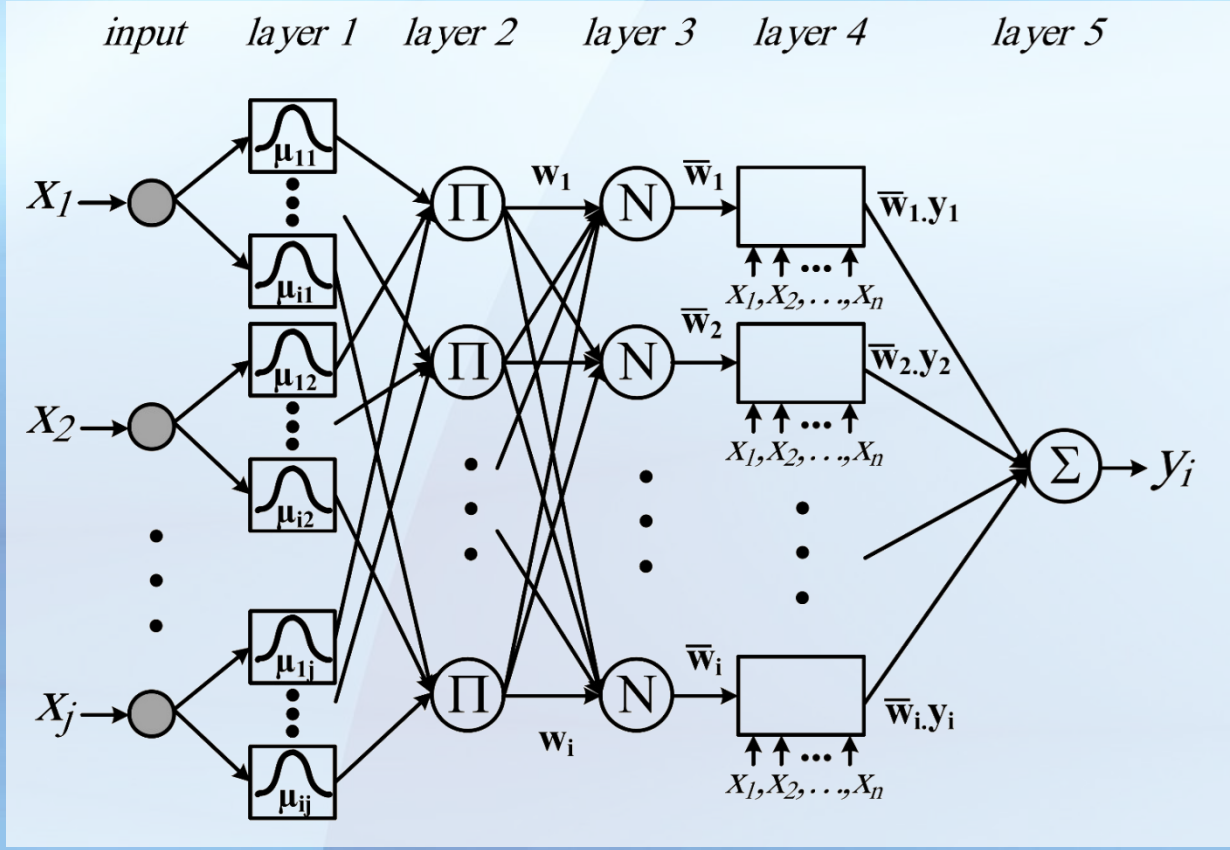
# سیستم استنتاج فازی: ساجینو

- 2nd generation: Takagi-Sugeno (TSK)



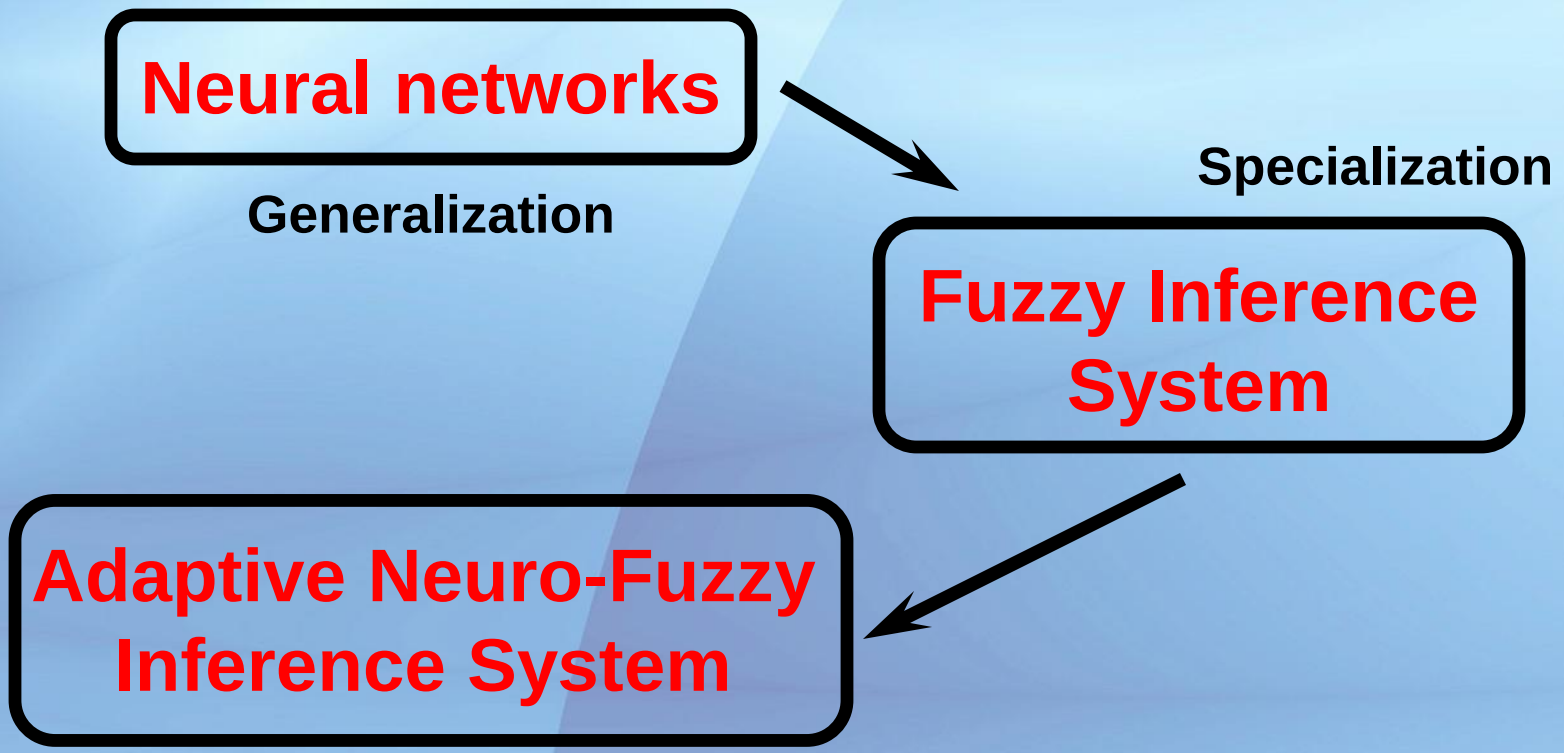
# مدلسازی فازی

- ساختار فازی TSK



# مدلسازی فازی

- Adaptive neuro-fuzzy Inference system (ANFIS)



# شناسایی سیستم با ANFIS

- روش های محاسباتی شبکه های عصبی
  - پس انتشار خطا یا Back-propagation

$$\Delta z = -\alpha \frac{\partial E}{\partial z} \qquad z_{i,j}(k+1) = z_{i,j}(k) + \Delta z_{i,j}(k)$$

  - روش حداقل مربعات خطا

$$A\theta + e = Y \quad \Rightarrow \quad \hat{\theta} = (A^T A)^{-1} A^T Y$$

# شناسایی سیستم با ANFIS

- حداقل مربعات بازگشتی

$$\widehat{\Theta}_k = \widehat{\Theta}_{k-1} + K_k \mathrm{E}_k,$$

$$\mathrm{E}_k = \left(Y_d - \Phi_k^T \widehat{\Theta}_{k-1}\right),$$

$$K_k = \left(\lambda + \Phi_k^T P_{k-1} \Phi_k\right)^{-1} P_{k-1} \Phi_k,$$

$$P_k = \lambda^{-1} \left(I - K_k \Phi_k^T\right) P_{k-1},$$

- ماتریس P: کوواریانس
- ماتریس K: بهره کالمن

# شناسایی سیستم با ANFIS

- روش ترکیبی برای تنظیم پارامترهای مدل
- Hybrid methods: BP + LS

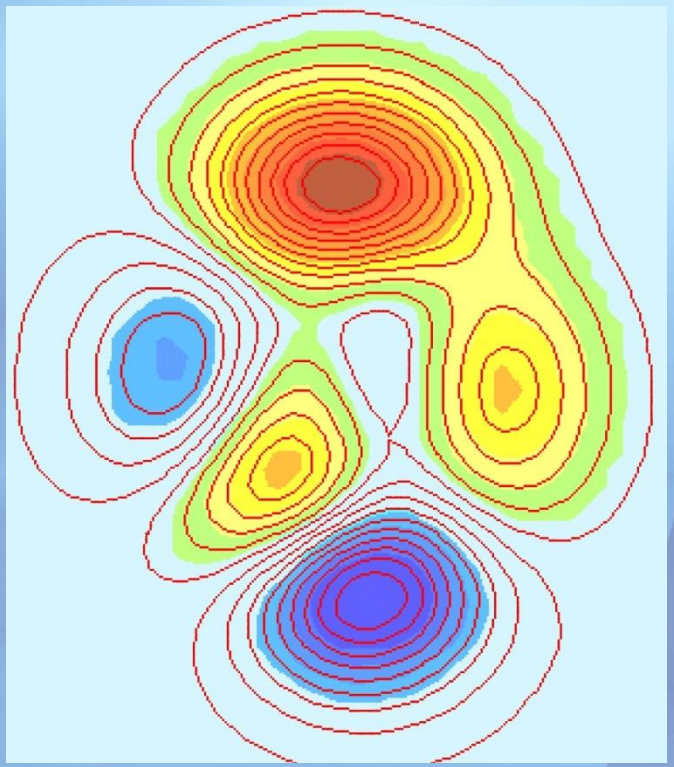
| | forward pass | backward pass |
|---|---|---|
| Membership functions | Fixed | steepest descent |
| Fuzzy rules | least-squares | fixed |

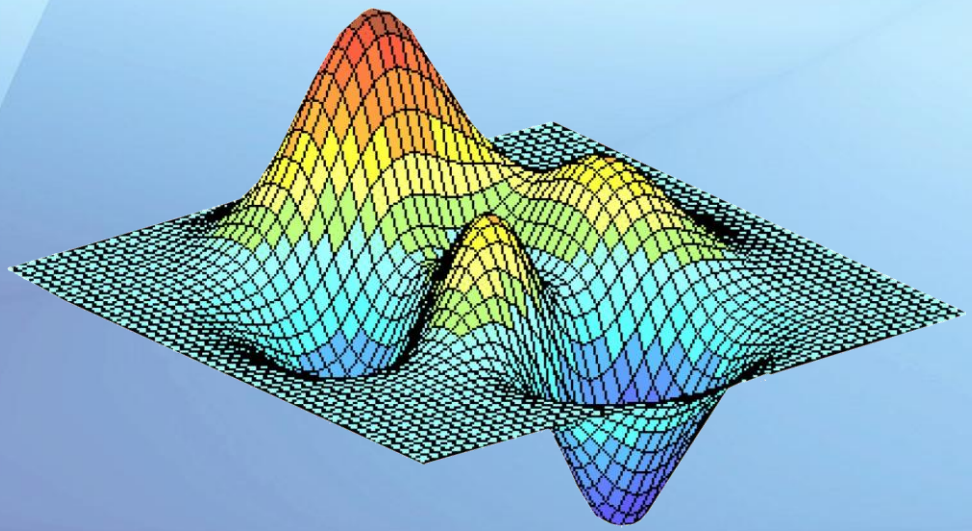
# شناسایی سیستم با ANFIS

| | Characteristics | Disadvantages |
|---|---|---|
| Least Square (fuzzy rule) | Batch process disregards previous state | No global searching ability |
| Back Propagation (membership functions) | Derivability of fuzzy partitions and T-norms used by FLC is required | Cannot use trapezoids nor "Min" |
| | Based on quadratic error cost | Symmetric error treatment & great outliers influence |

# شناسایی سیستم با ANFIS

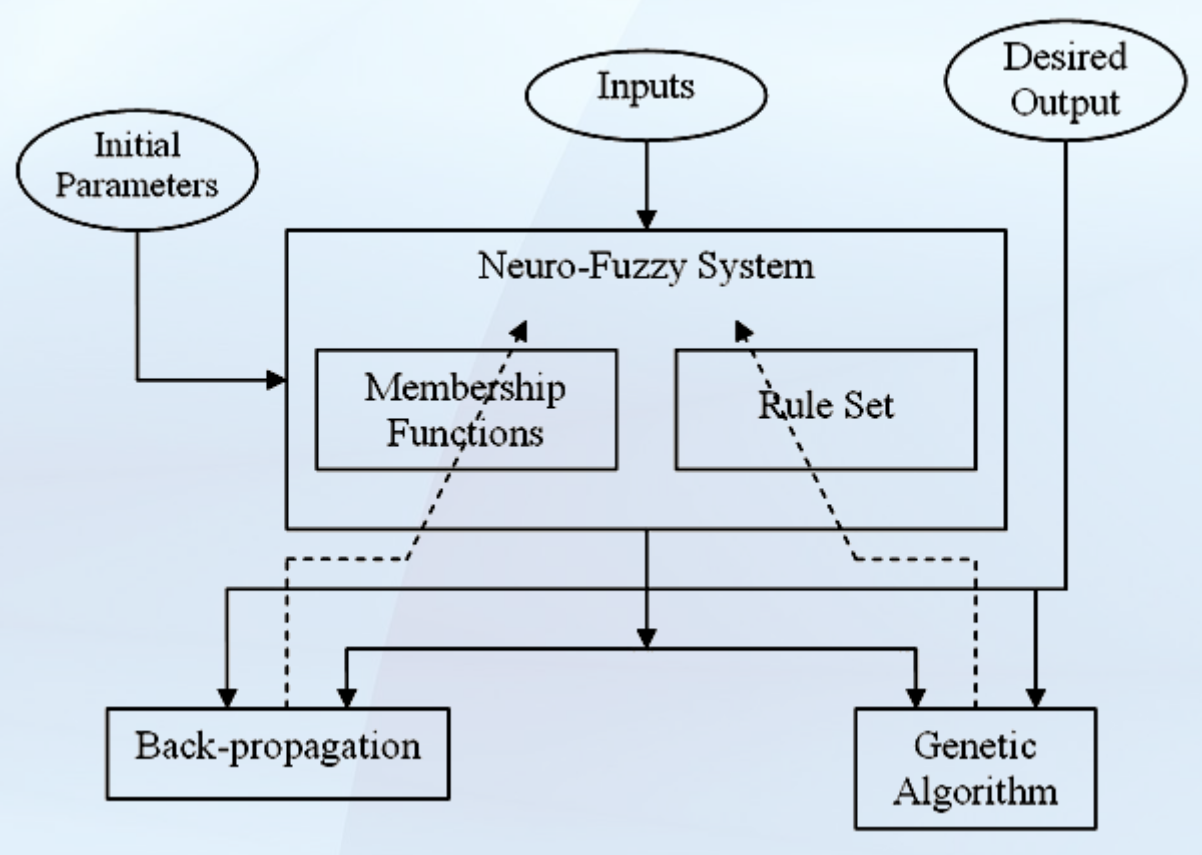
- روش های تکاملی
  - فرار کردن از نقاط منیمم محلی





# شناسایی سیستم با ANFIS

- روش ترکیبی: پس انتشار + الگوریتم ژنتیک



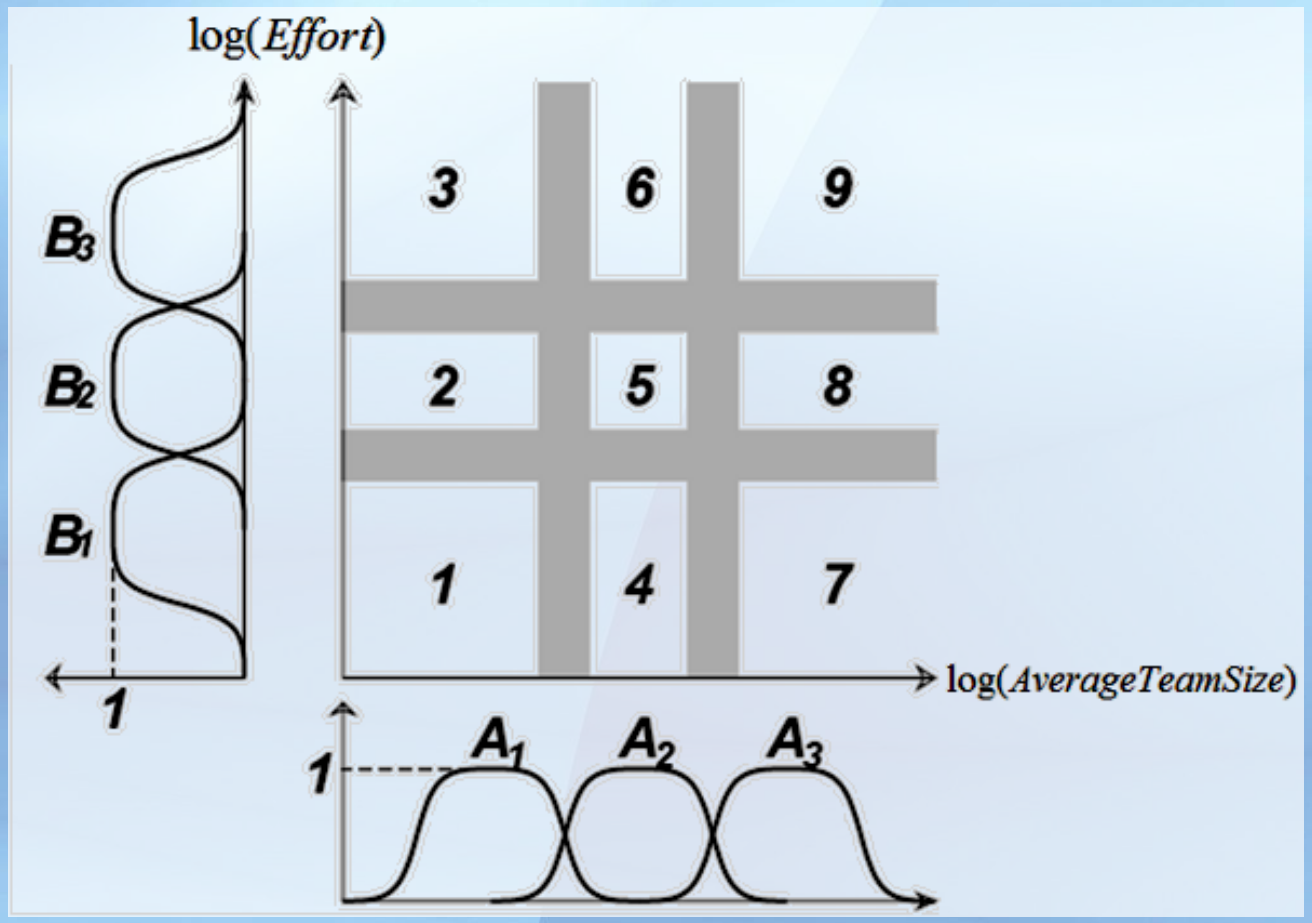
# EA vs. Classical Optimization

- تفاوت عمده روش های تکاملی و روشهای کلاسیک :

| Evolutionary algorithm | Classical optimization |
|---|---|
| Individual | Parameter vector |
| Population | Set of parameter vectors |
| Fitness | Inverse of loss function value |
| Fitness function | Inverse of loss function |
| Generation | Iteration |
| Application of genetic operators | Parameter vector update |

# تعیین ساختار مدل فازی

- روش تقسیم بندی (Grid Partitioning)



# تعیین ساختار مدل فازی

- روش توده یابی (Clustering Techniques)
  - دسته بندی بر اساس مشابهت یا عدم مشابهت
  - روش مناسبی برای کاهش درجه پیچیدگی مدلهای فازی
    - تعیین ساختار
    - تعیین قوانین
    - کاهش تعداد پارامترها
      - جلوگیری از over-fitting
      - افزایش سرعت محاسبه

# انواع روش توده یابی

- الگوریتم K-Means
  - تابع هزینه

$$I = \sum_{j=1}^{C} \sum_{i=1}^{N} \mu_{ji} ||\underline{u}(i) - \underline{c}_j||^2 ,$$

- C: تعداد توده
- $c_j$ : مرکز توده

where $\mu_{ji} = 1$ if the data sample $\underline{u}(i)$ is associated (belongs) to the cluster $j$ and $\mu_{ji} = 0$ otherwise.

  - به روز کردن مرکز در تکرار

$$\underline{c}_j = \frac{\sum_{i \in S_j} \underline{u}(i)}{N_j} ,$$

# انواع روش توده یابی

- الگوریتم Fuzzy C-Means (FCM)

$$I = \sum_{j=1}^{C} \sum_{i=1}^{N} \mu_{ji}^{\nu} ||\underline{u}(i) - \underline{c}_j||_{\underline{\Sigma}}^2 \qquad \text{with} \qquad \sum_{j=1}^{C} \mu_{ji} = 1 .$$

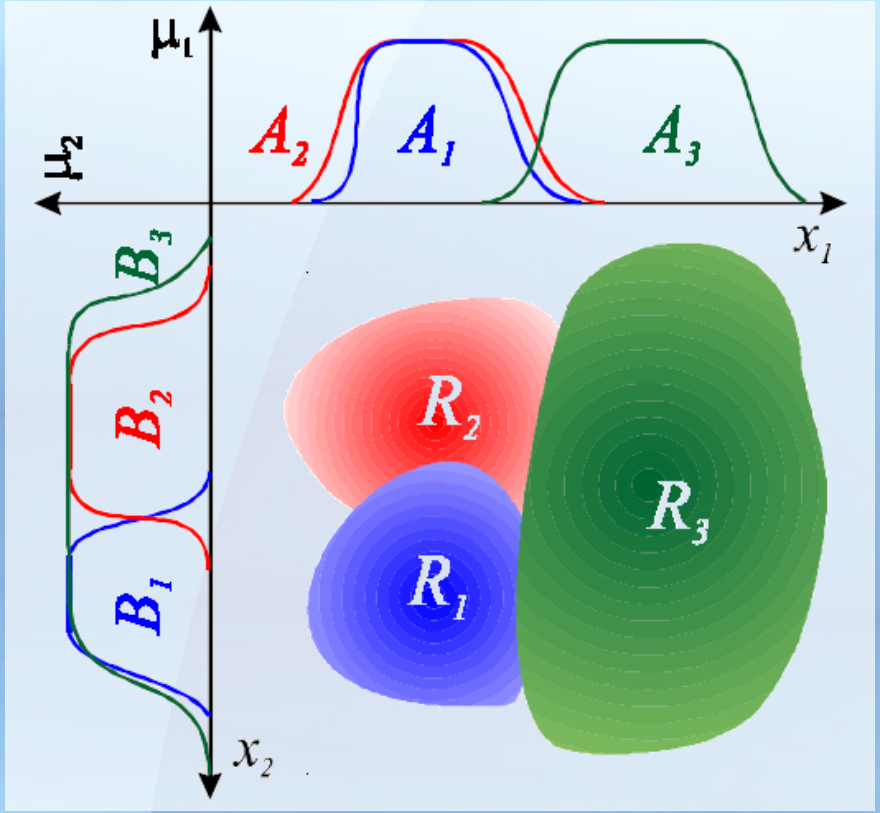
- به روز کردن مرکز و درجه عضویت توسط تکرار (پیکارد)

$$\mu_{ij} = \frac{1}{\sum_{l=1}^{C} \left( D_{ij,\underline{\Sigma}}^2 / D_{il,\underline{\Sigma}}^2 \right)^{\frac{1}{\nu-1}}}$$

$$\underline{c}_j = \frac{\sum_{i=1}^{N} \mu_{ij}^{\nu} \, \underline{u}_i}{\sum_{i=1}^{N} \mu_{ij}^{\nu}} .$$

# روش توده یابیFCM

- تعداد قوانین کاهش می یابد
- ساختار مدل و قوانین فازی تعیین می شود



# کلاسه بندی KNN

- K-Nearest Neighbor

- فرض کنید که هر تجربه می تواند به عنوان یک نقطه در یک فضای نمایش داده شود.
- برای یک نقطه خاص در این مجموعه، k نقطه را در جمعیت پیدا کنید که نزدیک ترین فاصله را به نقطه مورد نظر دارند.
- کلاس اکثریت این همسایگان، کلاس مربوط به نقطه انتخاب شده است.

# کلاسه بندی KNN

- الگوریتم KNN ساده ترین نوع الگوریتم کلاسه بندی است.
- این الگوریتم غیر پارمتری است و هیچ فرضی برای توزیع نقاط در نظر نمی گیرد.
- این الگوریتم بسیار تنبل بوده به این دلیل معنی که فاز یادگیری مشخصی ندارد و لذا بسیار سریع است.
- برای مقایسه شباهت مثالها نیاز به یک تابع فاصله دارد:
  - فاصله اقلیدسی

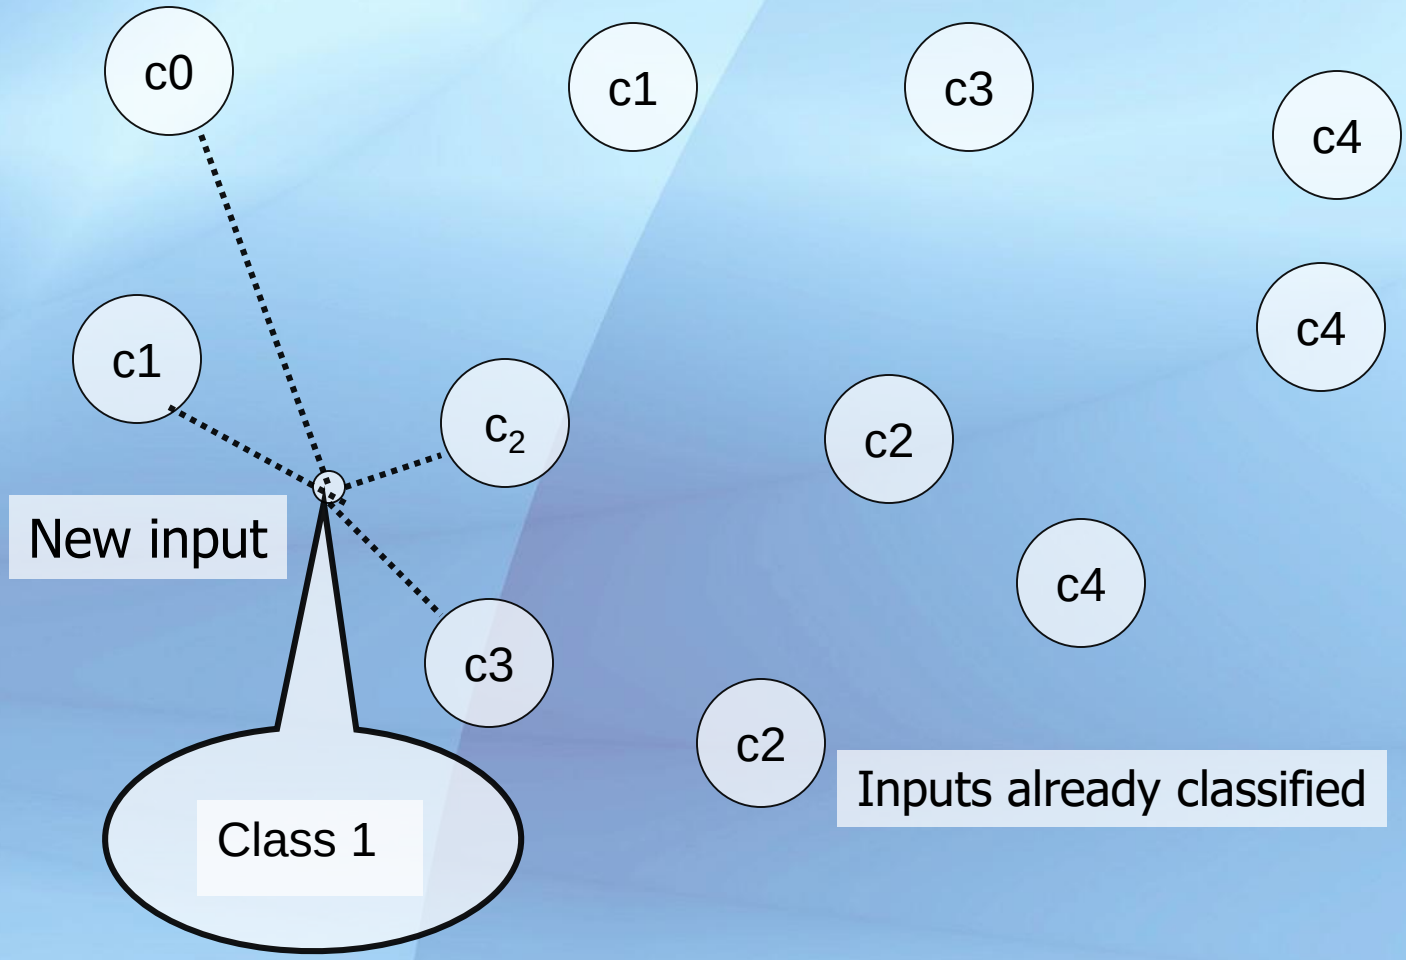
$$d(x_j, x_k) = \sqrt{\sum_i (x_{j,i} - x_{k,i})^2}$$

  - فاصله منهتن

$$d(x_j, x_k) = \sqrt{\sum_i | x_{j,i} - x_{k,i} |}$$

# کلاسه بندی KNN

- الگوریتم KNN مبتنی بر شباهت ویژگی ها است



# کلاسه بندی نایو- بیز

- Naïve Bayes Classification

- نایو- بیز روشی برای دسته‌بندی پدیده‌ها بر پایه احتمال وقوع یا عدم وقوع یک پدیده است.

- پایه این روش بر اساس احتمال شرطی رخدادها گذاشته شده است.

$$P(E \mid F) = \frac{P(EF)}{P(F)}$$

- اگر دو رخداد مستقل باشند

$$P(EF) = P(E)P(F)$$

# کلاسه بندی نایو- بیز

- توجه اینکه:

$$P(E|F)=\frac{P(EF)}{P(F)} \quad , \quad P(F|E)=\frac{P(EF)}{P(E)} \Rightarrow$$

$$P(E|F)P(F)=P(F|E)P(E)$$

- اگر رخدادهای $F_1 \ldots F_n$ ، $n$ رخداد مستقل باشند:

$$\bigcup_{i=1}^{n} F_i = S$$

- در این صورت

$$E = \bigcup_{i=1}^{n} EF_i$$

$$P(E)=\sum_{i=1}^{n} P(EF_i)=\sum_{i=1}^{n} P(E|F_i)P(F_i)$$

# کلاسه بندی نایو- بیز

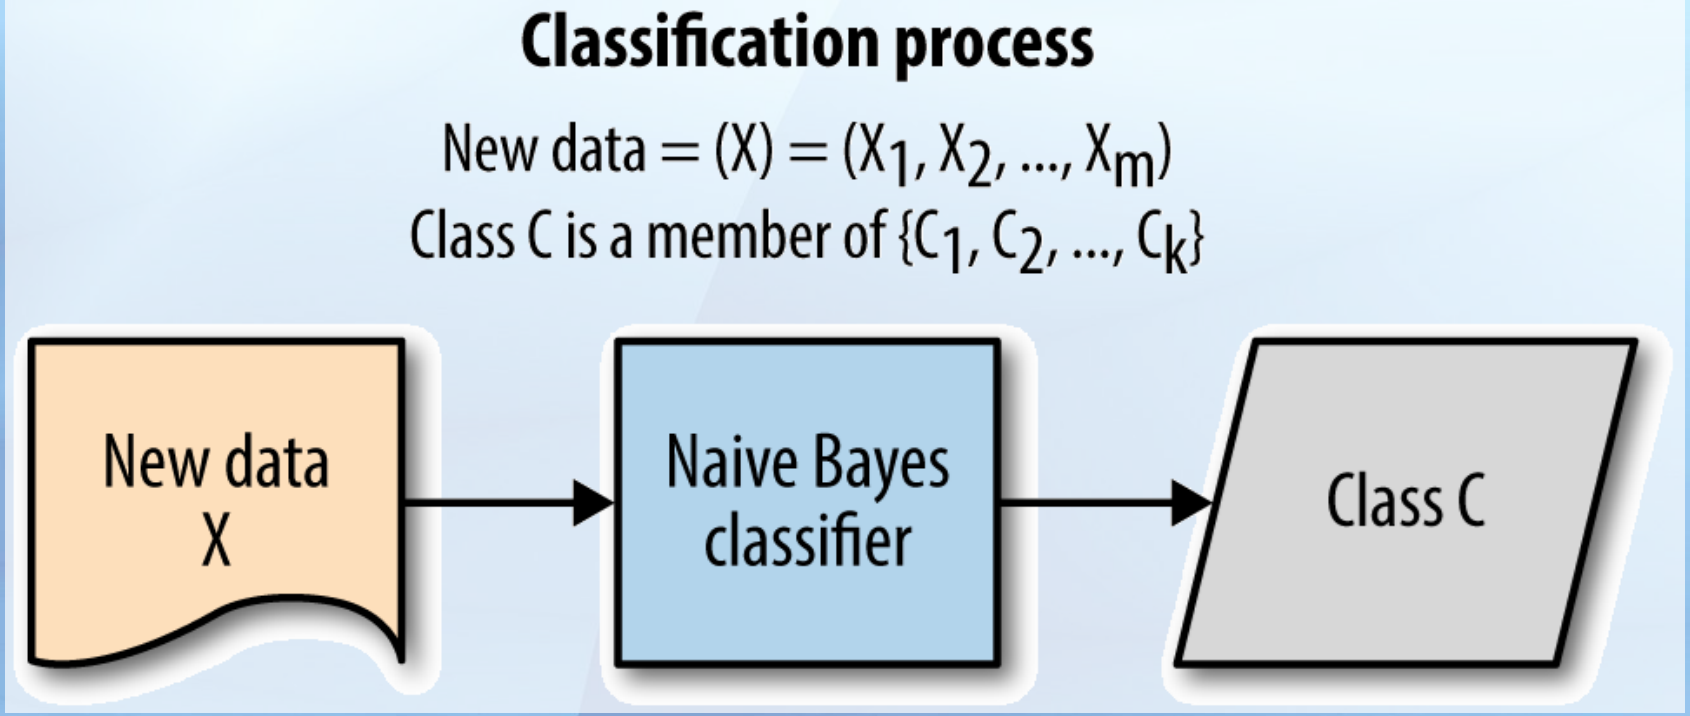
- حال فرض کنید رخداد $E$ اتفاق افتاده و می خواهیم پیدا کنیم که کدام یک از رخدادهای $F_i$ نیز اتفاق افتاده است.

$$P(F_i \mid E) = \frac{P(EF_i)}{P(E)}$$

$$= \frac{P(E \mid F_i)P(F_i)}{\sum_{i=1}^{n} P(E \mid F_i)P(F_i)}$$

# کلاسه بندی نایو- بیز

- فرض کنید بخواهیم فضای ویژگی X را به کلاس C عیب مرتبط کنیم



# کلاسه بندی نایو- بیز

- مشکل مدل سازی صریح $P(X_1,\ldots,X_n|C_j)$ آن است که معمولا پارامترهای زیادی وجود دارد:
  - اشغال فضای زیاد حافظه
  - زمانبری زیاد
  - حجم زیادی از داده های آموزش
- در صورتی ویژگی ها مستقل از هم باشند، بر اساس رابطه نایو- بیز می توان فرض کرد:

$$P(X_1,\ldots X_n|C_j)=\prod_{i=1}^{n}P(X_i|C_j)$$

# کلاسه بندی نایو- بیز

- لذا داریم:

$$P(C_j \mid X_1,\ldots X_n) = P(X_1,\ldots X_n \mid C_j)P(C_j)$$

$$= P(C_j)\prod_{i=1}^{n} P(X_i \mid C_j)$$

- نایو- بیز این کار را به شیوه ای بسیار ساده انجام می دهد؛ به سادگی $C_j$ را انتخاب می کند که بیشترین احتمال را با توجه به ویژگی های نقاط داده دارد.

$$y = \arg\max_{C_j} P(C_j)\prod_{i=1}^{n} P(X_i \mid C_j)$$

- این به عنوان قاعده تصمیم حداکثر Posteriori معروف است

# کلاسه بندی نایو- بیز

- فرآیند آموزش نایو- بیز آسان است.
  - احتمال $P(Y=v)$ را به صورت کسری از رکوردهای $Y=v$ تخمین بزنید.

$$P(Y=v)=\frac{Count(Y=v)}{\#\ records}$$

  - احتمال $P(X_i=u|Y=v)$ را به صورت کسری از رکوردهای $Y=v$ برای $X_i=u$ تخمین بزنید.

$$P(X_i=u|Y=v)=\frac{Count(X_i=u\wedge Y=v)}{Count(Y=v)}$$

# کلاسه بندی نایو- بیز

- در عمل برخی از این شمارها می توانند صفر باشند.
- این مشکل را با اضافه کردن تعدادی " ثابت مجازی" برطرف می کنند:

$$P(X_i = u|Y = v) = \frac{Count(X_i = u \wedge Y = v) + 1}{Count(Y = v) + 2}$$

- این عمل را نرم سازی یا Smoothing گویند.

# کلاسه بندی نایو- بیز

- فرض کنید $x_1, x_2, \ldots, x_n$ مقادیر یک مجموعه عددی در مجموعه اعداد آموزش باشند.
- در این صورت می توان مقدار احتمال هر یک از متغیرها را به صورت یک توزیع طبیعی با میانگین به شکل زیر تخمین زد:

$$\mu = \frac{1}{n}\sum_{i=1}^{n} x_i$$

$$\sigma = \frac{1}{n-1}\sum_{i=1}^{n}(x_i - \mu)^2$$

$$f(w) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(w-\mu)^2}{\sigma^2}}$$

فصل ششم

# ترکیب اطلاعات

# ترکیب اطلاعات

- این فرآیند شامل ترکیب اطلاعات (Information fusion) دریافتی از چندین سنسور و یا پایگاه داده مرتبط به هم، به منظور بهبود دقت استنتاج است.

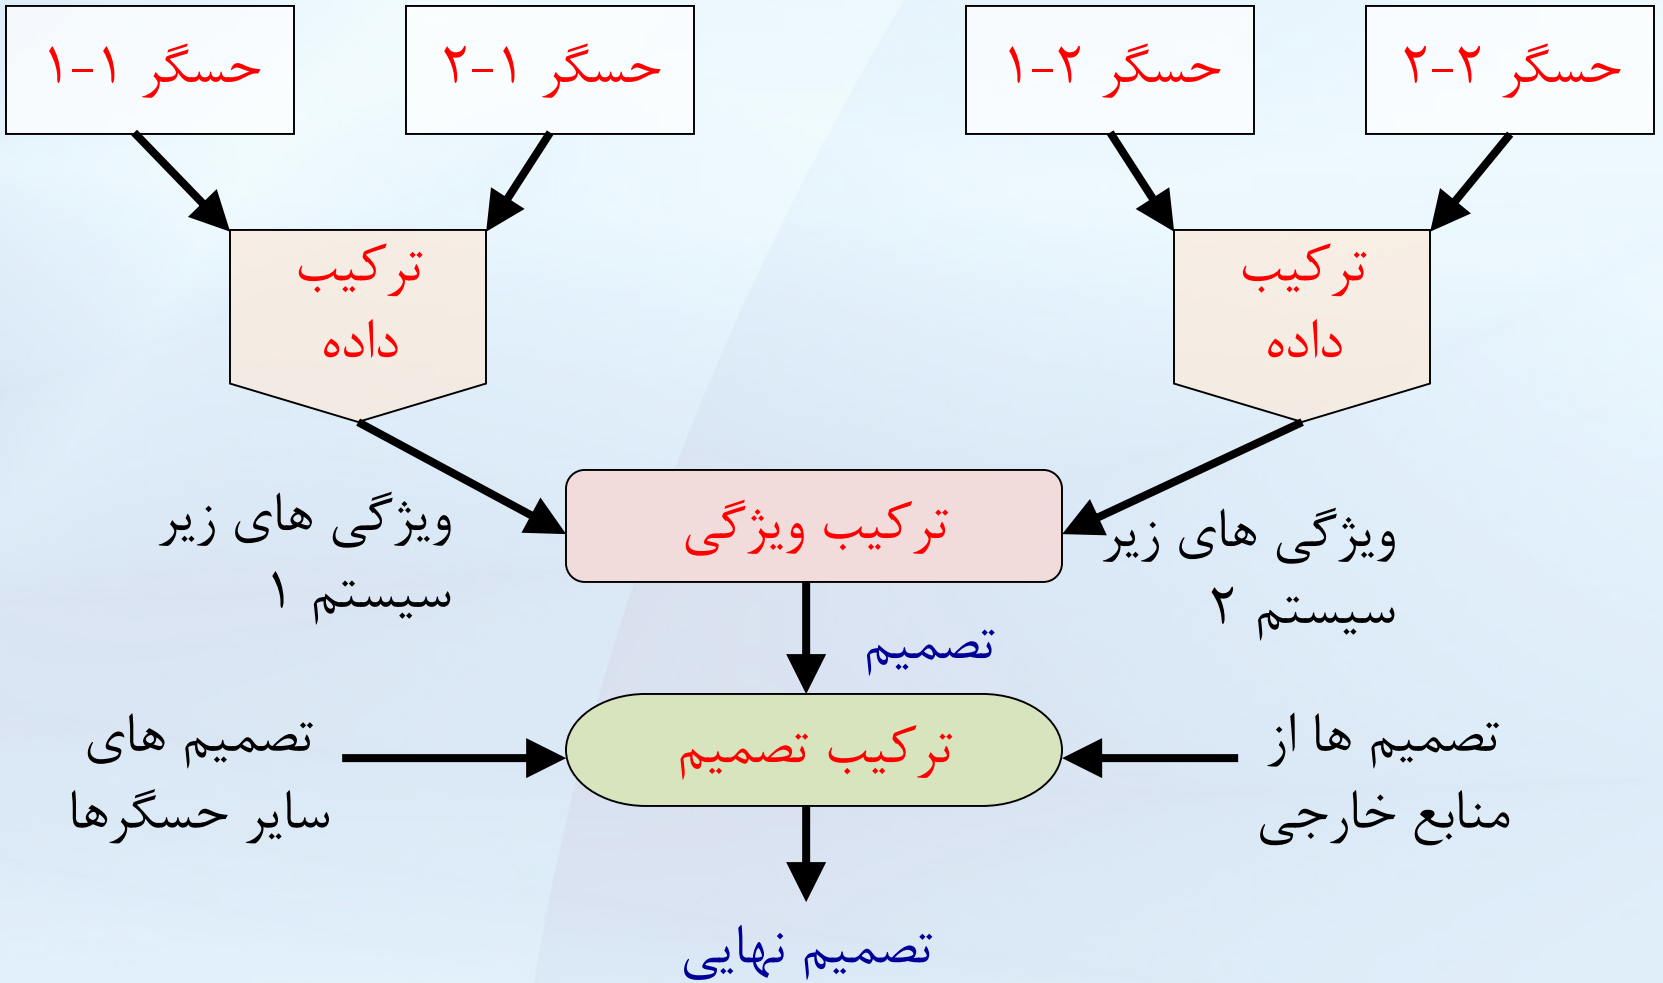
- به طور کلی ترکیب داده (Data fusion) و ترکیب اطلاعات (Information fusion) به عنوان مترادف به کار می روند، اما در برخی مواقع، ترکیب داده برای داده های خام (که به طور مستقیم از سنسورها بدست آمده) و ترکیب اطلاعات برای داده های از قبل پردازش شده به کار می رود

# ترکیب اطلاعات

- ترکیب اطلاعات ابتدا در سال ۱۹۷۳ توسط وزارت دفاع ایالات متحده معرفی شد
- ترکیب اطلاعات نظریه ای است که اطلاعات چندین منبع و یا سنسور را ترکیب و نتایج را دقیق تر و قابل اعتمادتر می سازد.
- در سیستم اطلاعات چند منبعی، معمولا هر بخش از اطلاعات ممکن است ناقص، نادرست و حتی متناقض باشد.
- اساس ترکیب اطلاعات، طبقه بندی داده ها، اطلاعات و تخمین و پیش یبنی حالت موجود است.

# ترکیب اطلاعات

## سطوح مختلف ترکیب اطلاعات




University of Guilan

# ترکیب سطح داده (سیگنال)

- در این سطح، اطلاعات منابع مختلف داده به طور مستقیم ترکیب می شوند.
- در این سطح، داده های جمع آوری شده از سنسورهایی که کمیت فیزیکی یا پدیده یکسانی را اندازه گیری می کنند، ترکیب می شوند.
- ترکیب سطح داده، صرفا به ترکیب داده های به دست آمده از سنسورهای متناسب (هم نوع) محدود می شود.

# ترکیب سطح ویژگی

- در این سطح، ویژگی های استخراجی از روش های مختلف و یا از سنسور های مختلف با یکدیگر ادغام می شوند.
- این سطح، یک سطح متوسط از ترکیب اطلاعات است که ترکیب ویژگی های سنسورهای نامتناسب (غیرهمنوع) را هم دربر می گیرد.
- تمام ویژگی ها به منظور پیدا کردن زیرمجموعه بهینه ای از ویژگی ها ترکیب می شوند

# ترکیب سطح تصمیم

- ترکیب سطح تصمیم یک ترکیب سطح بالا است.
- هدف آن ترکیب نتایج بدست آمده از کلاسه بندها به منظور فراهم کردن نتیجه بهتر است.
- ترکیب سطح ویژگی و سطح تصمیم از نظر مشابهت به هم نزدیک بوده و حتی در برخی موارد با یکدیگر تداخل هم دارند

# ترکیب اطلاعات

- فرض کنیم x متغیری است که مقادیرش را از مجموعهٔ A انتخاب کرده که برای آن، مقادیر $a_1,a_2,\ldots,a_n$ از منابع مختلف بدست آمده باشد.
- ترکیب اطلاعات عبارت است از ترکیب این قطعات اطلاعاتی برای بدست آوردن یک مقدار قابل ارائه بوده که با مشاهدات سازگار باشد:

$$F(a_1,a_2,\ldots,a_n)=\mathrm{b}$$

- که در آن b مقدار حاصل از ترکیب شدن باشد.

# ترکیب اطلاعات

- خواص عمومی ترکیب اطلاعات
- همانی بودن:

$$F(a,a,...,a)=a$$

- پیوستگی: تابع F باید در $a_1,a_2,\ldots,a_n$ پیوسته باشد
- یکنوایی و غیر کاهشی بودن

$$a'>a \Rightarrow F(a'_1,a'_2,...,a'_n)>F(a_1,a_2,...,a_n)$$

- بیطرفی Neutrality : برای تمام جایگشت های q :

$$q=\{1,2,..,n\}$$

$$F(a_1,a_2,...,a_n)=F(a_{q(1)},a_{q(2)},...,a_{q(n)})$$

# ترکیب اطلاعات

- شرکت پذیری: دارا بودن خاصیت شرکت پذیری اجازه می دهد اپراتوری که برای ترکیب دو آرگومان تعریف شده است، برای آرگومانهای بیشتری استفاده شود

$$F^{[n]}(a_1,a_2,\ldots,a_n) = F^{[1]}(a_1,F^{[n-1]}(a_2,\ldots,a_n))$$
$$= F^{[2]}(a_1,F^{[1]}(a_2,F^{[n-2]}(a_2,a_3,\ldots,a_n)))$$
$$= F^{[3]}(a_1,F^{[2]}(a_2,F^{[n-3]}(a_3,a_4,\ldots,a_n)))$$

# ترکیب اطلاعات

- ساده ترین محاسبه میانگین فرمول است:

$$\bar{a} = \frac{1}{n}\sum_{i=1}^{n} a_i$$

- اپراتور های بسیار دیگری نیز در این مورد وجود دارند که در حالت های خاص به فرمول فوق همگرا می شوند. فرم کلی این اپراتور ها که میانگین شبه حسابی نامیده می شود به صورت زیر است:

$$\mathrm{M}_f(a_1, a_2, \ldots, a_n) = f^{-1}\left(\frac{1}{n}\sum_{i=1}^{n} f(a_i)\right)$$

- که در آن f یک تابع پیوستهٔ اکیدا یکنوا می باشد.

# ترکیب اطلاعات

- می توان با معرفی وزن های $w_i$ که معرف میزان اهمیت معیار ها هستند و با شرط

$$\sum_{i=1}^{n} w_i = 1$$

اپراتور زیر را تعریف کرد :

$$M^{f}_{w_1, w_2, \ldots w_n}(a_1, a_2, \ldots, a_n) = f^{-1}\left(\frac{1}{n}\sum_{i=1}^{n} w_i f(a_i)\right)$$

# ترکیب اطلاعات

- اپراتور میانه: این اپراتور به صورت زیر تعریف می شود :

$$\text{med}(a_1, a_2, \ldots, a_n) = \begin{cases} a_{(\frac{n+1}{2})} & n : odd \\ \frac{1}{2}\left( a_{(\frac{n}{2})} + a_{(\frac{n}{2}+1)} \right) & n : even \end{cases}$$

$$a_{(1)} \le a_{(2)} \le \ldots \le a_{(n)}$$

# ترکیب اطلاعات

- اپراتور کمینه- بیشینه :

$$\mathrm{WMin}_{w_1,w_2,\ldots w_n}(a_1,a_2,\ldots,a_n)=\underset{i=1}{\overset{n}{Min}}\left[Max\left[1-w_i,a_i\right]\right]$$

$$\mathrm{WMax}_{w_1,w_2,\ldots w_n}(a_1,a_2,\ldots,a_n)=\underset{i=1}{\overset{n}{Max}}\left[Min\left[w_i,a_i\right]\right]$$

- که در آن:

$$\underset{i=1}{\overset{n}{Max}}\, w_i = 1$$

# عملگر میانگین وزنی مرتب شده

- Ordered Weighted Averaging Operator (OWA)
- این روش یک کلاس پارامتریک از اپراتورهای متوسط تجمعی را فراهم می کند.
- تعداد زیادی از اپراتورهای معروف قابل توجه مانند حداکثر، میانه، میانگین و حداقل، عضو این کلاس هستند.
- آنها به واسطه توانایی خود برای مدل سازی روش های تجمعی به طور گسترده ای در هوش محاسباتی مورد استفاده قرار گرفته اند

# OWA

- روابط حاکم بر OWA به صورت زیر است

$$W = [w_1, w_2, \ldots, w_n]^T$$

$$w_i \in [0,1]$$

$$\sum_{i=1}^{n} w_i = 1$$

$$F(a_1, a_2, \ldots, a_n) = \sum_{i=1}^{n} w_i b_i$$

# OWA

- Orness: درجه ای که تجمع آن مانند یک عملگر Max است.

$$Orness(W) = \frac{1}{n-1}\sum_{i=1}^{n}(n-i)w_i$$

- پراکندگی (Dispersion): چه مقدار از اطلاعات در جمع بندی بر اساس W استفاده می شود

$$Disp(W) = -\sum_{i=1}^{n} w_i \ln(w_i)$$

# OWA

- وزن OWA را با درجه ی از پیش تعیین شده از Orness و آنتروپی را حداکثر کنید

MaxDisp(W):

subject to $\alpha$=Orness(W)

$$\sum_{i=1}^{n} w_i = 1 \qquad w_i \in [0,1]$$

# OWA

- یادگیری OWA از مشاهدات اطلاعات نیز امکان پذیر است.
- مشاهدات داده ها (m نمونه) $(a_{k1}, a_{k2}, \ldots, a_{kn})$
- مشاهدات مقدار فیوز شده (m نمونه) $d_k \quad , k = 1, 2, \ldots, m$

$$F(a_{k1}, a_{k2}, \ldots, a_{kn}) = d_k \ , k = (1, m) \quad \Rightarrow$$
$$b_{k1} w_1 + b_{k2} w_2 + \ldots + b_{kn} w_n = d_k \ , k = (1, m)$$

- بردار وزن OWA با به حداقل رساندن خطای لحظه $e_k$ با توجه به وزن ها

$$e_k = \frac{1}{2}(b_{k1} w_1 + b_{k2} w_2 + \ldots + b_{kn} w_n - d_k)^2$$

# OWA

- قید:

$$\sum_{i=1}^{n} w_i = 1 \ , \ w_i \in [0,1]$$

- تبدیل:

$$w_i = e^{\lambda_i} \left( \sum_{j=1}^{n} e^{\lambda_j} \right)^{-1}$$

- که در آن:

$$\forall \lambda_i : \quad w_i > 0 \ , \ \sum_{k=1}^{n} w_k = 1$$

# OWA

- مساله کمینه سازی غیرمقید

$$e_k = \frac{1}{2}\left(\sum_{i=1}^{n} b_{ki}\, e^{\lambda_i} \left(\sum_{j=1}^{n} e^{\lambda_j}\right)^{-1} - d_k\right)^2$$

- حداقل گرادیان شیب

$$\lambda_i(l+1) = \lambda_i(l) - \beta \frac{\partial e_i}{\partial \lambda_i}\Big|_{\lambda_i = \lambda_i(l)} \quad , i = (1, n)$$

# نظریه شواهد

- Evidence Theory

- روش های مختلفی به منظور ترکیب اطلاعات نظیر روش بیزین، نظریه شواهد دمپستر- شافر ، الگوریتم شبه فازی و شبکه عصبی مصنوعی و ... جهت تحلیل و افزایش قابلیت اطمینان اطلاعات وجود دارد.
- تئوری ریاضی شواهد، توسط دمپستر معرفی و بعد ها توسط شافر در سال ۱۹۷۶ توسعه یافت و به عنوان ابزاری قدرتمند برای تصمیم گیری در شرایط نامطمئن شناخته شد.

# نظریه شواهد

- نظریه شواهد دمپستر- شافر می تواند به عنوان یک تعمیم کلی از تئوری بیزین در نظر گرفته شود.
- این روش برای مقابله با داده های ناقص، نامعینی و عدم اطمینان در فرآیند تصمیم گیری مورد استفاده قرار می گیرد.
- سه تابع اساسی در نظریه شواهد DS وجود دارد:
  - تابع تخصیص احتمال اساسی ( Basic probability assignment یا m) ،
  - تابع اعتقاد (Belief)
  - تابع مقبولیت (Plausibility)

# نظریه شواهد

- تابع BPA مقداری در بازه [0 1] را به مجموعه A تخصیص می دهد.
- مقدار m(A) تنها به مجموعه A مربوط می شود و هیچ ادعایی در مورد زیرمجموعه A ندارد.

$$m : P(X) \rightarrow [0 \quad 1]$$

$$m(\varnothing) = 0 \quad , \quad \sum_{A \in P} m(A) = 1$$

# نظریه شواهد

- تابع اعتقاد (Bel):

- The sum of all the BPAs of the proper subset $B \subseteq A$

$$Bel(A) = \sum_{B|B \subseteq A} m(B)$$

- تابع مقبولیت (Pl):

- The sum of all the BPAs of the proper subset B as $B \cap A \neq \varnothing$

$$Pl(A) = \sum_{B|B \cap A \neq \varnothing} m(B)$$

# نظریه شواهد

- رابطه بین تابع $Pl(A)$ و تابع $Bel(A)$ عبارت است از

$$Bel(A) \le Pl(A)$$

$$Pl(A) = 1 - Bel(\overline{A})$$

- احتمال $P(A)$ از رویداد A

$$Bel(A) \le P(A) \le Pl(A) \xrightarrow{if\ Pl(A)=Bel(A)} P(A) = Pl(A) = Bel(A)$$

# نظریه شواهد

- مفهوم اصلی نظریه D-S می تواند برای توسعه قوانین ترکیب استفاده شود که در آن اندازه گیری های اعتقاد و مقبولیت براساس همگرایی BPA برآورد می شود.

- قانون ترکیب D-S را می توان به سادگی به عنوان یک (conjugative operation) عملیات اتصال AND در نظر گرفت، که در آن در یک تابع اعتقاد، شواهد منتخب را در عملیات ترکیب را به هم متصل می کند

# نظریه شواهد

- عملیات اتصال در D-S به صورت انجام می شود:

$$m = m_2 \oplus m_2 \oplus \ldots \oplus m_p \quad \Rightarrow$$

$$m(\mathrm{A}) = \frac{1}{1-K} \sum_{\substack{\forall A_i \\ \cap_{i=1}^{p} A_i = \mathrm{A}}} \prod_{i=1}^{p} m_i(A_i)$$

$$m(\varnothing) = 0$$

$$K = \sum_{\substack{\forall A_i \\ \cap_{i=1}^{p} A_i = \varnothing}} \prod_{i=1}^{p} m_i(A_i)$$

- که در آن $m_i$ ها تابع BPA مجموعه های محلی $A_i$ هستند

# نظریه شواهد

- K نشان دهنده یک جرم احتمالی اساسی مربوط به تداخل میان منابع شواهد است که از طریق جمع حاصل ضرب توابع جرم تمام مجموعه ها با اشتراک غیرتهی تعیین می شود.
- این قانون جابجایی پذیر، شرکت پذیر و ناپیوسته است.

- نکته: برای انتخاب m(A) یک کلاسیفایر یا طبقه بند می توان از دقت آن بر اساس coefficient of determination یا $R^2$ استفاده نمود.

# قانون ترکیب یاگر

- قانون نظریه شواهد D-S توسط یاگر 1987 برای حل مشکل در هنگام تضاد شواهد بهبود داده شد.
- تئوری شواهد D-S در مواجهه با شرایطی که شواهد نظرات متناقضی داشتند دچار نتیجه گیری اشتباه می شد.
- این مشکل با حذف فاکتور نرمال ساز ($1-K$) از مخرج تابع تخصیص احتمال اساسی برطرف می شود.

# قانون ترکیب یاگر

- Ground Probability Mass Assignment ($q$)

$$q(\mathrm{A}) = \sum_{\substack{\forall A_i \\ \cap_{i=1}^{p} A_i = \mathrm{A}}} \prod_{j=1}^{r} m_j(A_i)$$

$$q(\varnothing) \geq 0$$

- در روش یاگر مقدار $q(\varnothing)$ می تواند یک مقدار برابر یا بزرگتر از صفر داشته باشد که نشانه تضارب آرا است.

# قانون ترکیب یاگر

- در این صورت، احتمالات پایه می توانند به توابع تخصیص احتمال اساسی از مجموعه یونیورسال تبدیل شود:

$$m^{Y}(\Delta) = q(\varnothing) + q(\Delta)$$

- فاکتور اهمیت یا importance factor: $\delta_i$
- فاکتور تضارب آرا یا conflicting of evidence: $\phi_i$

# قانون ترکیب یاگر

- قانون ترکیب یاگر به صورت زیر خواهد بود:

$$[\delta_i, \phi_i] \in m_i \quad , \quad \phi_i = 1 - \delta_i$$

$$q(\mathrm{A}) = \sum_{\substack{\forall A_i \\ \bigcap_{i=1}^{p} A_i = \mathrm{A}}} \prod_{j=1}^{r} \delta_j(A_i) + \sum_{\substack{\forall A_i \\ \bigcap_{i=1}^{p} A_i = \mathrm{A}}} \left( \sum_{\substack{k=1 \\ j \neq k}}^{r} \sum_{\substack{j=1 \\ j \neq k}}^{r} \delta_j(A_i) \phi_k(A_i) \right)$$

$$q(\varnothing) = \sum_{\substack{\forall A_i \\ \bigcap_{i=1}^{p} A_i = \varnothing}} \prod_{i=1}^{r} m_i(A_i)$$

# قانون ترکیب یاگر

- برای انتخاب $\delta_i$ یک طبقه بند می توان از دقت آن بر اساس coefficient of determination یا $R^2$ استفاده نمود
- در این صورت مقدار فاکتور تضارب آرا $\phi_i=1-\delta_i$ می تواند بدست آید.
- رابطه بین GPA و D-S :

$$m(A)=\frac{q(A)}{1-q(\varnothing)}$$

# قانون ترکیب یاگر

- مثال: استفاده از ۴ کلاسیفایر متفاوت در شرایط تضاد آراء

| No. | SVM | | NNPR | | ANFIS | | LVQ | | Final result | | Ignorance Factor | Alarm |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| | Normal | Faulty | Normal | Faulty | Normal | Faulty | Normal | Faulty | Normal | Faulty | | |
| 1 | 1 | 0 | 1 | 0 | 0 | 1 | 0 | 1 | 0.6002 | 0.3961 | 0.0037 | Disable |
| 2 | 0 | 1 | 1 | 0 | 1 | 0 | 0 | 1 | 0.5604 | 0.4358 | 0.0038 | Disable |
| 3 | 1 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0.6356 | 0.3607 | 0.0036 | Disable |
| 4 | 1 | 0 | 1 | 0 | 0 | 1 | 1 | 0 | 0.9911 | 0.0082 | 7.017e−4 | Disable |
| 5 | 1 | 0 | 1 | 0 | 1 | 0 | 0 | 1 | 0.9959 | 0.0037 | 4.837e−4 | Disable |
| 6 | 0 | 1 | 1 | 0 | 1 | 0 | 1 | 0 | 0.9893 | 0.0099 | 7.742e−4 | Disable |
| 7 | 1 | 0 | 0 | 1 | 1 | 0 | 1 | 0 | 0.9922 | 0.0072 | 6.589e−4 | Disable |
| 8 | 0 | 1 | 0 | 1 | 1 | 0 | 1 | 0 | 0. 3961 | 0.6002 | 0.0037 | Enable |
| 9 | 1 | 0 | 0 | 1 | 0 | 1 | 1 | 0 | 0.4358 | 0.5604 | 0.0038 | Enable |
| 10 | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 0.3607 | 0.6356 | 0.0036 | Enable |
| 11 | 0 | 1 | 0 | 1 | 1 | 0 | 0 | 1 | 0. 0082 | 0.9911 | 7.017e−4 | Enable |
| 12 | 0 | 1 | 0 | 1 | 0 | 1 | 1 | 0 | 0. 0037 | 0.9933 | 4.837e−4 | Enable |
| 13 | 1 | 0 | 0 | 1 | 0 | 1 | 0 | 1 | 0.0099 | 0.9893 | 7.742e−4 | Enable |
| 14 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 1 | 0.0072 | 0.9922 | 6.589e−4 | Enable |

# قانون ترکیب یاگر

- مثال: دو کلاسیفایر SVM و LVQ با دقت های تعریف شده زیر برای یک عیب مشخص نظر متضاد داشته باشند:

$$e_{SVM} = [1, 0] \qquad \alpha_1 = 0.9276$$

$$e_{LVQ} = [0 , 1] \qquad \alpha_2 = 0.8834$$

- مقدار $R^2$ کلاسیفایر SVM = 0.9276
- تخمین سالم بودن: 100 خرابی: 0
- مقدار $R^2$ کلاسیفایر LVQ = 0.8834
- تخمین سالم بودن: 0 خرابی: 100

$$E_{SVM} = [e_{SVM} * \alpha_1 \ : \ \phi_1 = 1 - \alpha_1]$$

$$E_{LVQ} = [e_{LVQ} * \alpha_2 \ : \ \phi_2 = 1 - \alpha_2]$$

$$E_{LVQ}' * E_{SVM} = \begin{bmatrix} 0 & 0 & 0 \\ 0.8194 & 0 & 0.0640 \\ 0.1082 & 0 & 0.0084 \end{bmatrix}$$

# قانون ترکیب یاگر

- با در نظر گرفتن دقت متفاوت دو طبقه بند در تشخیص عیب :

| $A_1$=normal $A_2$=faulty | | | | |
|---|---|---|---|---|
| $E_{LVQ}$ \ $E_{SVM}$ | $\delta_1(A_1)= 0.9276$ | $\delta_1(A_2)= 0$ | $\phi_1 = 0.0724$ | |
| $\delta_2(A_1)= 0$<br>$\delta_2(A_2)= 0.8834$<br>$\phi_2= 0.1166$ | $\delta_2(A_1) \times \delta_1(A_1) = 0$<br>$\delta_2(A_2) \times \delta_1(A_1) =0.8194$<br>$\phi_2 \times \delta_1(A_1) =0.1082$ | $\delta_2(A_1) \times \delta_1(A_2) =0$<br>$\delta_2(A_2) \times \delta_1(A_2) =0$<br>$\phi_2 \times \delta_1(A_2) =0$ | $\delta_2(A_1) \times \phi_1=0$<br>$\delta_2(A_2) \times \phi_1=0.0640$<br>$\phi_2 \times \phi_1=0.0084$ | |
| | q(A) | q(∅) | q(A) / (1- q(∅)) | m(A) |
| Normal<br>Faulty | 0+0+0.1082=0.1082<br>0+0.0640+0=0.0640 | 0.8194 | 0.1082/(1-0.8194)<br>0.0640/(1-0.8194) | 0.5991<br>0.3544 |

# قانون ترکیب یاگر

- مثال: دو کلاسیفایر SVM و LVQ با دقت های تعریف شده تعریف شده زیر برای یک عیب مشخص نظر متضاد داشته باشند ولی هر یک به صورت اشتباه سالم بودن و معیوب بودن را به صورت کامل تشخیص ندهند.

$e_{SVM}=[0.8136 \quad 0.114 \quad 0.0724]; \qquad \alpha_1 = 0.91$

$e_{LVQ}=[0.0313 \quad 0.8521 \quad 0.1166]; \qquad \alpha_2 = 0.88$

- مقدار $R^2$ کلاسیفایر SVM = 0.91
- تخمین سالم بودن: 81.36 خرابی: 11.4 عدم اطمینان: 7.24
- مقدار $R^2$ کلاسیفایر LVQ = 0.88
- تخمین سالم بودن: 3.13 خرابی: 85.21 عدم اطمینان: 11.66

# قانون ترکیب یاگر

- در این صورت خواهیم داشت:

$$E_{SVM}=[e_{SVM}* \alpha_1 : \ \phi_1 = 1-\alpha_1]'$$
$$E_{LVQ}=[e_{LVQ}* \alpha_2 : \ \phi_2 = 1-\alpha_2]$$

$$E_{LVQ}{}' * E_{SVM} = \begin{bmatrix} 0.0204 & 0.5552 & 0.0760 & 0.0888 \\ 0.0029 & 0.0778 & 0.0106 & 0.0125 \\ 0.0018 & 0.0494 & 0.0068 & 0.0079 \\ 0.0025 & 0.0675 & 0.0092 & 0.0108 \end{bmatrix}$$

# قانون ترکیب یاگر

- با در نظر گرفتن دقت متفاوت دو طبقه بند در تشخیص عیب :

| | $A_1$= condition 1 | $A_2$= condition 2 | $A_3$= condition 3 | |
|---|---|---|---|---|
| $E_{LVQ}$ \ $E_{SVM}$ | $\delta_1(A_1)= 0.8136$ | $\delta_1(A_2)= 0.114$ | $\delta_1(A_3)= 0.114$ | $\phi_1 = 0.09$ |
| $\delta_2(A_1)= 0.0313$ | $\delta_2(A_1) \times \delta_1(A_1) = 0.0204$ | $\delta_2(A_1) \times \delta_1(A_2) = 0.5552$ | $\delta_2(A_1) \times \delta_1(A_3) = 0.0760$ | $\delta_2(A_1) \times \phi_1= 0.0888$ |
| $\delta_2(A_2)= 0.8521$ | $\delta_2(A_2) \times \delta_1(A_1) = 0.0029$ | $\delta_2(A_2) \times \delta_1(A_2) = 0.0778$ | $\delta_2(A_2) \times \delta_1(A_3) = 0.0106$ | $\delta_2(A_2) \times \phi_1= 0.0124$ |
| $\delta_2(A_3)= 0.1166$ | $\delta_2(A_3) \times \delta_1(A_1) = 0.0018$ | $\delta_2(A_3) \times \delta_1(A_2) = 0.0494$ | $\delta_2(A_3) \times \delta_1(A_3) = 0.0068$ | $\delta_2(A3) \times \phi_1= 0.0079$ |
| $\phi_2= 0.12$ | $\phi_2 \times \delta_1(A_1) =0.0025$ | $\phi_2 \times \delta_1(A_2) = 0.0675$ | $\phi_2 \times \delta_1(A_3) = 0.0092$ | $\phi_2 \times \phi_1=0.0108$ |
| | | | | |
| | q(A) | q(∅) | q(A) / (1- q(∅)) | m(A) |
| Normal | 0.0204+0.0888+0.0025=0.1117 | 0.6959 | 0.1117/(1-0.6959) | 0.3673 |
| Faulty | 0.0778+0.0125+0.0675=0.1578 | | 0.1578/(1-0.6959) | 0.5186 |
| | 0.0068+0.0079+0.0092=0.0239 | | 0.0239/(1-0.6959) | 0.0786 |
| | | | Ignorance =0.0355 | |

# انتگرال فازی

- این عملگر، به کمک اندازه های فازی  برای حل مسائلی که در آنها ارزیابی یک کمیت که به معیارهای زیادی وابستگی دارد، مناسب است.
- اندازۀ فازی قابلیت انعطاف بسیار بیشتری نسبت به  توابع احتمال دارد.
- با وجود قدرتمندی این ابزار،  بکارگیری آن به نسبت دشوار است .

# انتگرال فازی

- اگر مجموعهٔ معیارها را با $X=\{x_1,x_2,\ldots,x_n\}$، و مجموعهٔ توانی آنرا با $\rho(X)$ نشان دهیم، اندازه فازی روی $X$ یک تابع به صورت:

$$\mu : \rho(X) \rightarrow [0,1]$$

تعریف می شود که شرایط زیر برای آن برقرار است:

$$\mu(\phi)=0 \quad , \quad \mu(X)=1$$

- اگر $A \subset B$ باشد:

$$\mu(A) \le \mu(B)$$
$$A,B \in \rho(X)$$

- می توان $\mu(A)$ را به عنوان وزن درجهٔ اهمیت مجموعهٔ معیارهای $A$ در نظر گرفت.

# انتگرال فازی

- تعریف: فرض کنیم که $\mu$ یک اندازهٔ فازی بر روی مجموعهٔ معیارهای $X$ باشد. انتگرال فازی گسستهٔ Sugeno بر روی مقادیر $a_1,a_2,\ldots,a_n$ که در بازه $[0,1]$ قرار دارند به صورت زیر تعریف می شود :

$$S_\mu(a_1,a_2,\ldots,a_n)=\max_{i=1}^{n}\left(\min\left(a_{(i)},\mu(A_{(i)})\right)\right)$$

- که در آن $i=1,2,\ldots,n$ و $a_{(i)}$ یک جایگشت از $a_i$ هاست به طوری که

$$a_{(1)}\le a_{(2)}\le\cdots<a_{(n)}$$

$$a_{(i)}=\left\{x_{(i)},\cdots,x_{(n)}\right\}$$

# انتگرال فازی

- تعریف : انتگرال فازی گسستهٔ Choquet بر روی مقادیر $a_1,a_2,\ldots,a_n$ که در بازه [0,1] قرار دارند به صورت زیر تعریف می شود.

$$C_\mu(a_1,a_2,\ldots,a_n)=\sum_{i=1}^{n}(a_{(i)}-a_{(i-1)})\,\mu(A_{(i)})$$

- که در آن i=1,2,…,n و $a_{(i)}$ یک جایگشت از $a_i$ هاست به طوری که

$$a_{(1)}\le a_{(2)}\le\cdots<a_{(n)}$$

$$a_{(i)}=\{x_{(i)},\cdots,x_{(n)}\}$$

# انتگرال فازی

- انتگرال های فازی Sugeno و Choquet با هم تفاوت اساسی دارند.
  - انتگرال فازی Sugeno بر پایهٔ اپراتور های غیر خطی Min و Max بنا نهاده شده است.
  - انتگرال فازی Choquet با اپراتور های خطی پیاده سازی می شود.

# انتگرال فازی

- انتگرال فازی Choquet با اندازه فازی $\mu$، یک میانگین حسابی وزن دار خواهد بود که وزن های $w_i$ آن $\mu(\{x_i\})$ باشد.
- هر اپراتور OWA با وزن های $w_i$ یک انتگرال Choquet می باشد که اندازهٔ فازی آن با رابطهٔ زیر تعریف می شود :

$$\mu(A) = \sum_{j=0}^{i-1} w_{n-j}, \quad \forall A$$

$$\mu(A) = \sum_{j=0}^{i-1} w_{n-j}, \quad \forall A$$

# انتگرال فازی

- مینیمم و ماکزیمم وزندار حالات ویژه ای از انتگرال فازی Sugeno هستند
- هر ترکیب دلخواه از اپراتور های Max و Min می تواند به وسیلهٔ یک انتگرال Choquet یا Sugeno با اندازهٔ فازی مناسب نمایش داده شود.
- به عنوان مثال

$$Max\left(\left(Min\left(a_1,a_3\right)\right),\left(Min\left(a_2,a_4\right)\right)\right)$$

را می توان بوسیلهٔ اندازهٔ فازی $\mu$

$$\mu\left(\left\{x_1,x_3\right\}\right)=\mu\left(\left\{x_2,x_4\right\}\right)=1$$

نمایش داد به صورتی که:

و سایر ضرایب ، صفر باشند

فصل هفتم

# رتبه بندی ویژگی ها

# رتبه بندی ویژگی ها

- اهمیت رتبه بندی ویژگی ها در انتخاب تاثیرگذار ترین ویژگی ها در تشخیص عیب در یک سیستم است.
- در فرآیند عیب یابی، ویژگی های مناسب باید تعریف و با توجه به متغیرهای غالب انتخاب شده برای شناسایی عیب استخراج شوند.
- با وجود استفاده از رویکردهای تشخیص خطا قوی و قابل اعتماد، انتخاب ویژگی های ضعیف یا غیر مرتبط ممکن است باعث اشتباه تصمیم گیری و آلارم های کاذب شود.

# Relief

- روش های انتخاب ویژگی ها را می توان در دو گروه اصلی زیر تقسیم نمود:
  - روش فیلتر filter-type : انتخاب متغیر با انتخاب یک معیار ارزیابی مناسب برای ارزیابی و مرتب سازی متغیرها انجام می شود، که در آن یک آستانه برای حذف متغیرهای زیر آستانه بکار گرفته می شود.
  - انتخاب بسته ای wrapper selection : زیرمجموعه ویژگی بهینه با ارزیابی عملکرد هر زیر مجموعه ویژگی، بدست می آید. هدف بدست آوردن بهترین عملکرد به ازای انتخاب ویژگی ها است

# Relief

- الگوریتم Relief یک رویکرد مبتنی بر فیلتر است که به طور گسترده ای مورد استفاده قرار گرفته است.
- ویژگی ها به صورت جداگانه بر اساس ارتباط آنها با داده های هدف مطلوب، وزن دهی می شوند.
- این امتیاز بر اساس نزدیکی ویژگی ها به نزدیکترین محدوده ویژگی های کلاس های مشابه و حداکثر فاصله از نزدیک ترین همسایگان از کلاس های مختلف

# Relief

- مراحل عملکرد:

1. از میان مجموعه نمونه های آموزشی، یک زیرمجموعه نمونه انتخاب می شود
2. کاربر بایستی تعداد نمونه ها در این زیرمجموعه را مشخص کرده باشد و آن را به عنوان ورودی به الگوریتم ارائه دهد
3. الگوریتم به صورت تصادفی یک نمونه از این زیرمجموعه را انتخاب می‌کند
4. سپس برای هر یک از ویژگی‌های این نمونه، نزدیک‌ترین برخورد (Nearest Hit) و نزدیک‌ترین شکست (Nearest Miss) را بر اساس معیار اقلیدسی پیدا می‌کند

# Relief

- مزایا
  - برای ویژگی های دارای نویز یا ویژگی های دارای همبستگی، خوب کار می کند
  - پیچیدگی زمانی آن به صورت خطی و تابعی از تعداد ویژگی ها و تعداد نمونه های مجموعه نمونه می باشد.
  - هم برای داده های پیوسته و هم برای داده های صوری خوب کار می کند
- معایب
  - ویژگی هایی که دارای افزونگی باشند را پیدا نمی کند.

# Relief-F

- به طور کلی، کیفیت $W[A]$ برای ویژگی $A$ برای یک مورد $I_0$ به صورت زیر بدست می آید:

$$W[A]=\sum_{i=1}^{a}\left[\sum_{B\neq Class(A)}\left[\frac{P(B)\times diff(A,I_0,I_M)}{i}\right]-\frac{diff(A,I_0,I_H)}{i}\right]$$

- که در آن $I_M$ نزدیکترین شکست و $I_H$ نزدیکترین برخورد در همسایگی است.
- تفاوت بین مورد $I$ و $I_0$ است.

$$diff(A,I_0,I)$$

# روش ارزیابی فاصله جبران شده

- Compensation Distance Evaluation Technique

- این روش توسط Lei et al (2008) ارائه شده و روش کارآمد برای انتخاب ویژگی های غالب در میان بردارهای اصلی و رتبه بندی ارتباط هر یک از ویژگی ها است.
- ویژگی هایی بر اساس نمره CDET خود که می بایست در محدوده [۰،۱] باشد، قابل شناسایی بوده و در صورت کم بودن ارتباط نادیده گرفته می شوند.

# CDET

- با توجه به مجموعه ویژگی های شرایط A

$$\left\{ {}^{k}T_{i,j}, q = 1,2,...,Q_j \; ; \; j = 1,2,...,J \; ; k = 1,2,...,K \right\}$$

- ${}^{k}T_{i,j}$ برابر با $k$ امین مقدار ویژه از $q$ امین نمونه در $j$ امین شرایط است. $Q_j$ شماره نمونه از $j$ امین شرایط و $K$ شماره ویژگی از هر شرایط است

# CDET

- کیفیت رتبه بندی ویژگی ها بر اساس نسبت فاصله متوسط نمونه ها در شرایط مشابه ($DS_k$) و میانگین فاصله بین نمونه های وضعیت مختلف ($DD_k$) بدست می آید

$$DS_k = \frac{1}{J}\sum_{j=1}^{J}\frac{1}{Q_j \times (Q_j - 1)}\sum_{l,q=1}^{Q_j}\left|{}^{k}T_{i,j} - {}^{k}T_{l,j}\right|$$

$$l,q = 1,2,\ldots,Q_j \quad , \quad l \neq q$$

$$DD_k = \frac{1}{J \times (J-1)}\sum_{j,e}^{J}\left|{}^{k}T_e - \frac{1}{Q_j}\sum_{i-1}^{Q_j}{}^{k}T_{i,j}\right|$$

$$j,e = 1,2,\ldots,J \quad , \quad j \neq e$$

# ویلکاکسون- مان- ویتنی

- Wilcoxon-Mann-Whitney (WMW)

- این روش یک روش رتبه دهی نوع فیلتر است که به صورت مجزا توسط ویلکاکسون در ۱۹۴۵ و مان و ویتنی در ۱۹۴۷ ارائه شد.
- WMWیک آزمون غیر پارامتری است که به طور گسترده ای برای رتبه بندی نمونه ها در شرایطی که نگرانی در مورد عادی بودن، چولگی و یا نقاط دور افتاده در مجموعه داده وجود داشته باشد، مورد استفاده قرار می گیرد.

# WMW

- مقدار UWMW یک کمیت آماری برای مقایسه دو گروه مستقل به صورت زیر است

$$X = \{x_1, \ldots, x_r\} \quad Y = \{y_1, \ldots, y_n\}$$

$$U_{WMW} = \frac{1}{r.n} \sum_{i=1}^{r} \sum_{j=1}^{n} 1_{x_i > y_i}$$

که در آن:

$$1_{x_i > y_i} = \begin{cases} 1 & : \quad x_i > y_i \\ 0 & : \quad otherwise \end{cases}$$

# کولبک - لیبر

- Kullback-Leibler distance / divergence (KLID)
- این روش در سال ۱۹۵۱ ارائه و یکی دیگر از روش های فیلتر پایه است. این روش بر اساس برآورد انتروپی نسبی متغیرهای ورودی کار می کند.
- KLID برای دو احتمال گسسته توزیع F و G به صورت زیر محاسبه می شود و نزدیکی توزیع احتمالی F را به توزیع کاندیدای G اندازه گیری می کند.

$$D_{KL}(F \| G) = \sum_i f_i \ln\left(\frac{f_i}{g_i}\right) \quad , \quad D_{KL} \geq 0$$

# KLID

- که در آن:

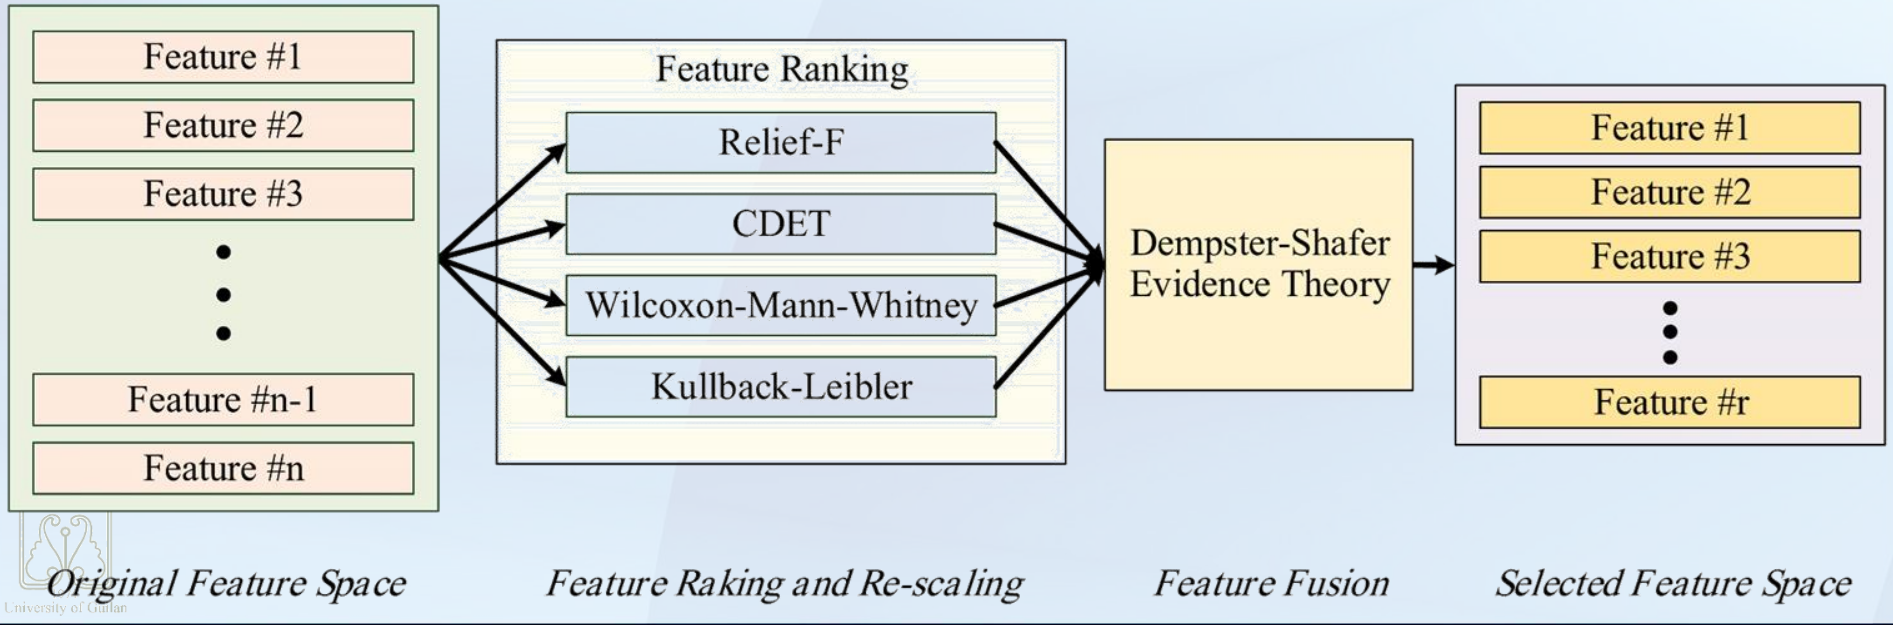
$$F = \{f_i\} \qquad G = \{g_i\}$$

- مقدار $D_{KL}$ در F و G غیر متقارن بوده و مقدار آن در صورت منطبق بودن کامل دو مجموعه صفر می شود.
- با افزایش اختلاف بین دو توزیع تصادفی، آنتروپی نسبی آن افزایش می یابد
- در فرآیند انتخاب ویژگی، مجموعه ای از ویژگی هایی که تراکم بیشتری برای هر کلاس متفاوت را نتیجه دهند، انتخاب می شوند

# ترکیب سطح ویژگی

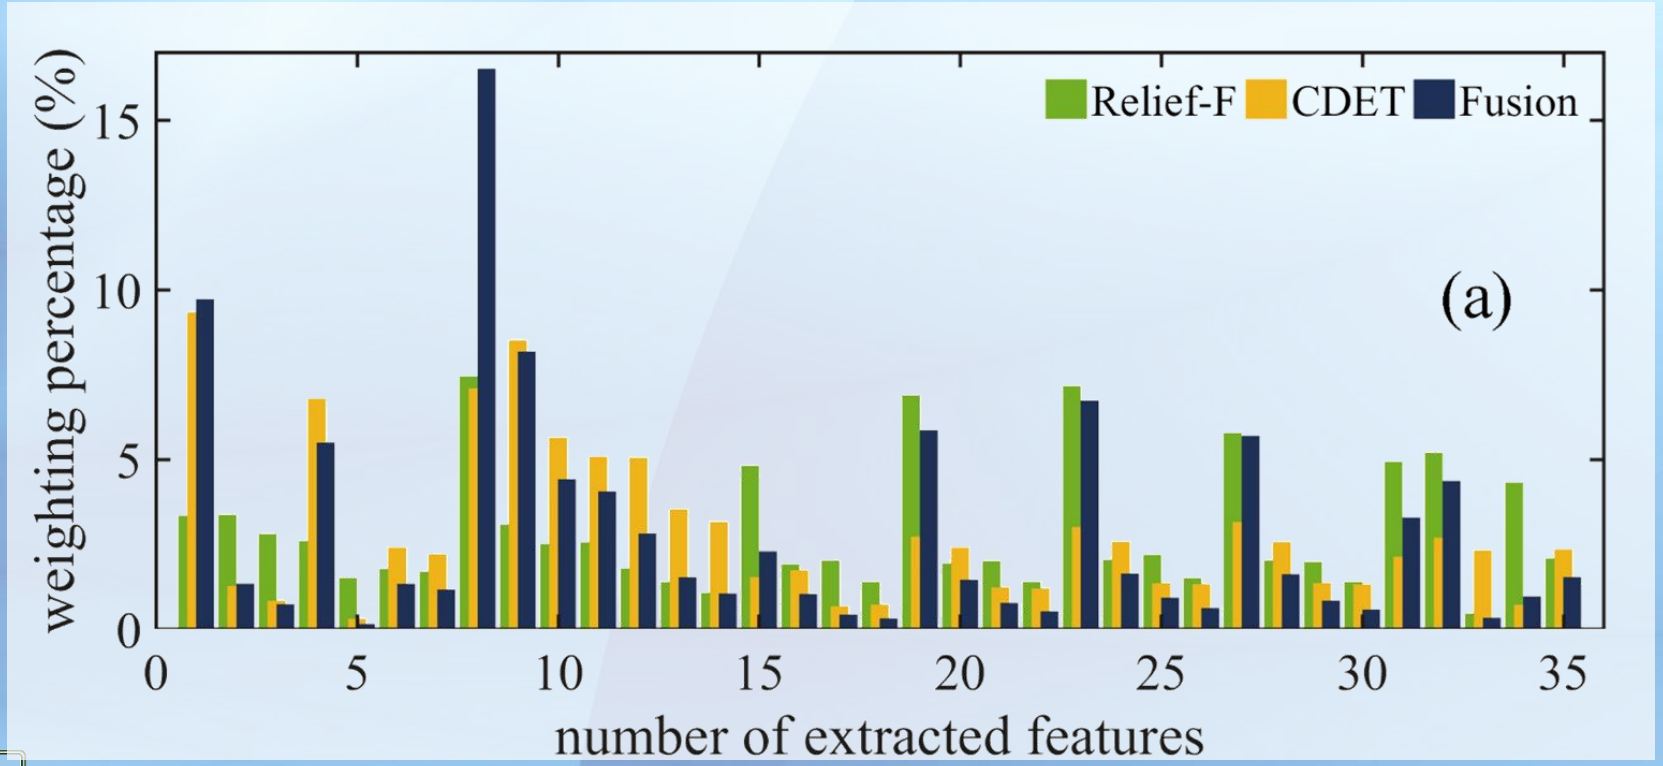
- می توان ویژگی های رتبه بندی شده توسط روش های مختلف را با هم ترکیب نمود.

- Moradi, M., Chaibakhsh, A., Ramezani, A., (2018). An intelligent hybrid technique for fault detection and condition monitoring of a thermal power plant, Applied Mathematical Modelling, Volume 60, Pages 34-47.



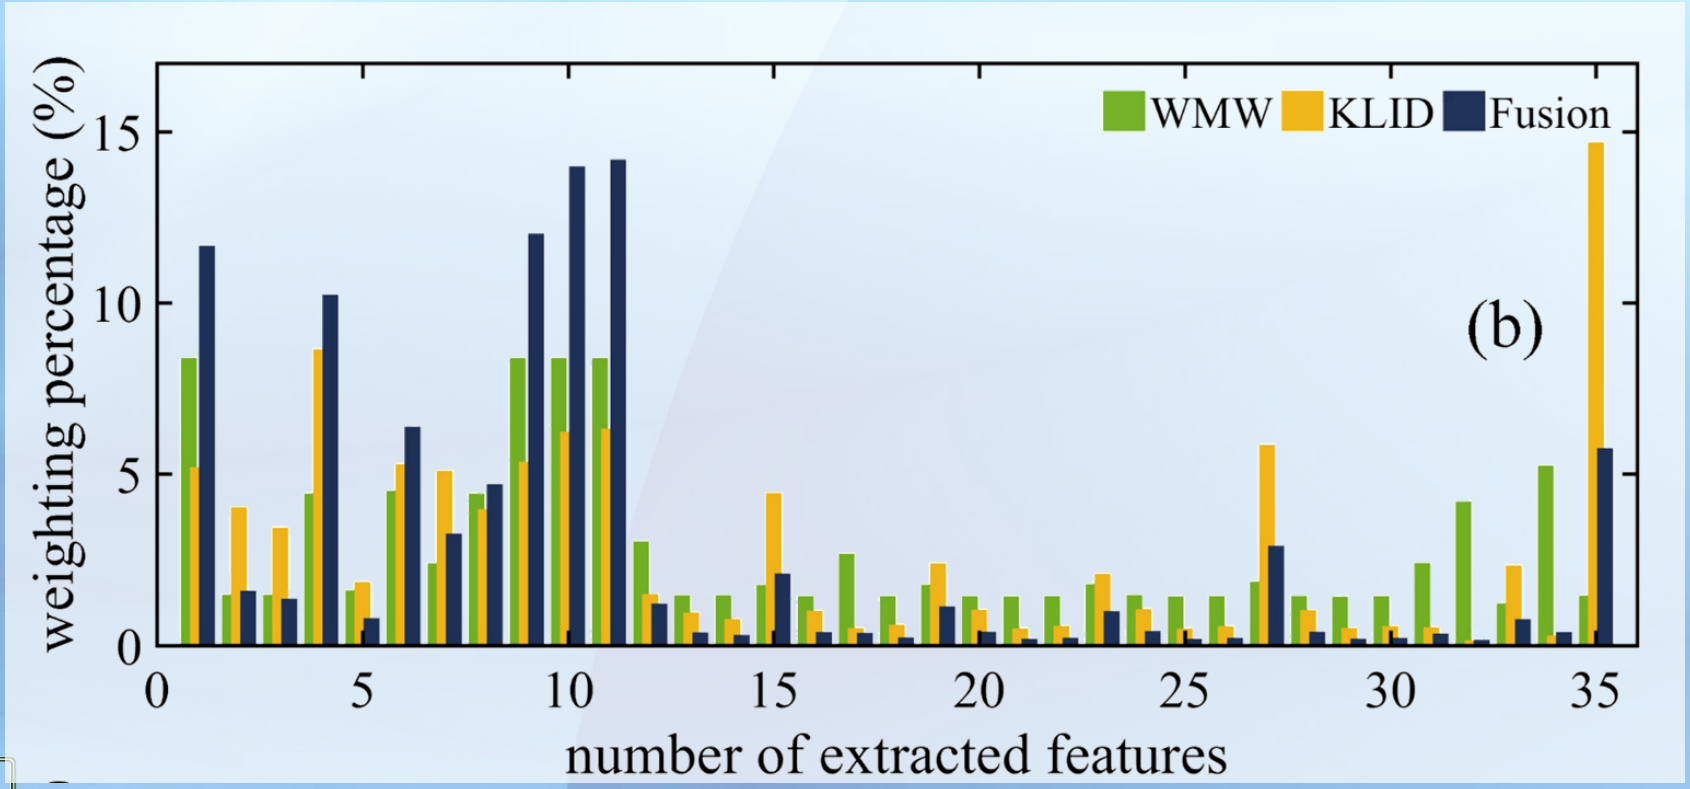
# ترکیب سطح ویژگی

- نتیجه حاصل از ترکیب در سطح ویژگی برای ویژگی های رتبه بندی شده با CDET و Relief-F



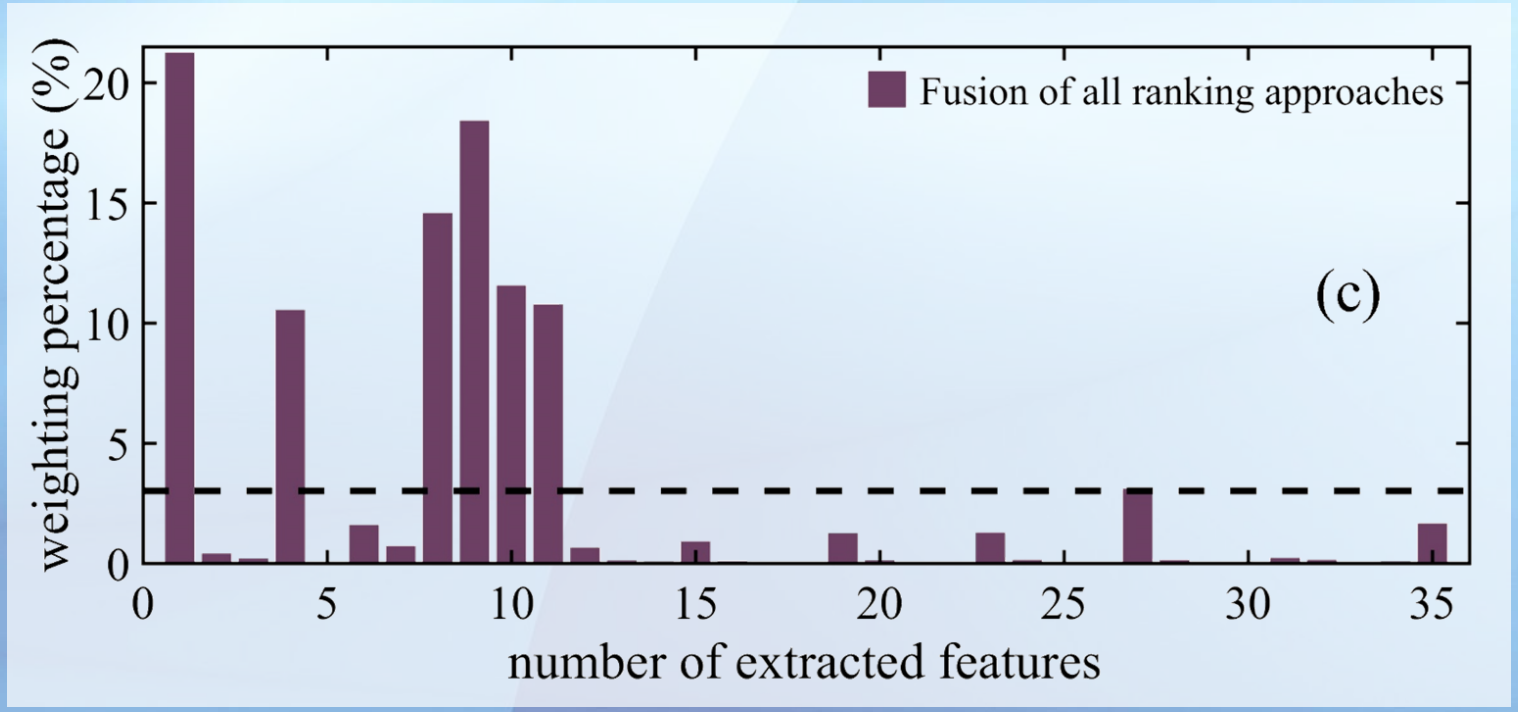
# ترکیب سطح ویژگی

- نتیجه حاصل از ترکیب در سطح ویژگی برای ویژگی های رتبه بندی شده با KLID و WMW

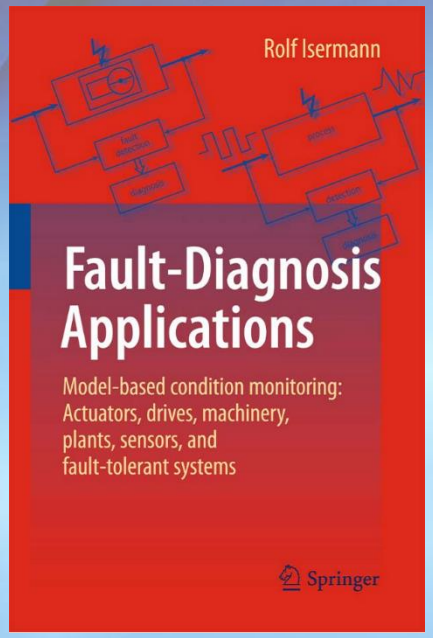


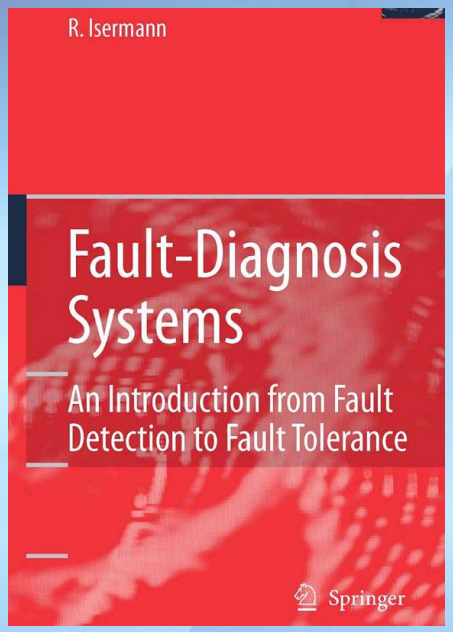
# ترکیب سطح ویژگی

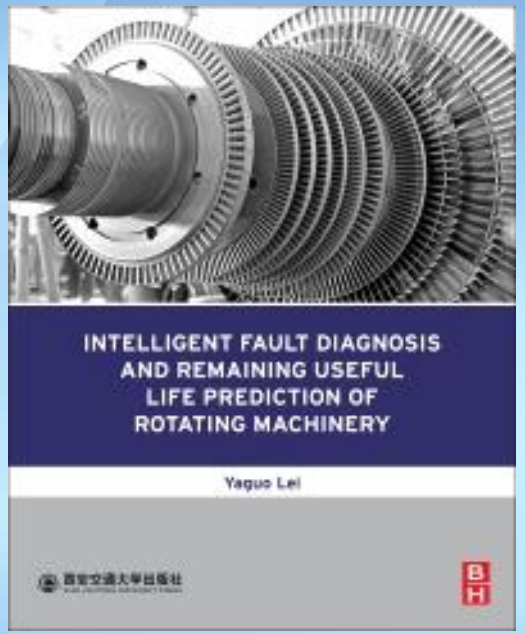
- حاصل از ترکیب ۴ رتبه بندی ویژگی

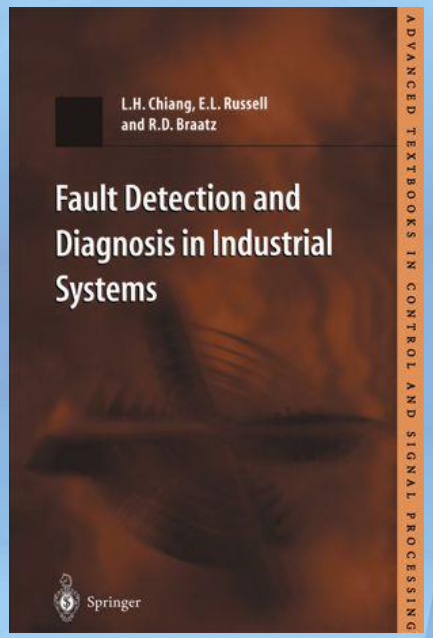


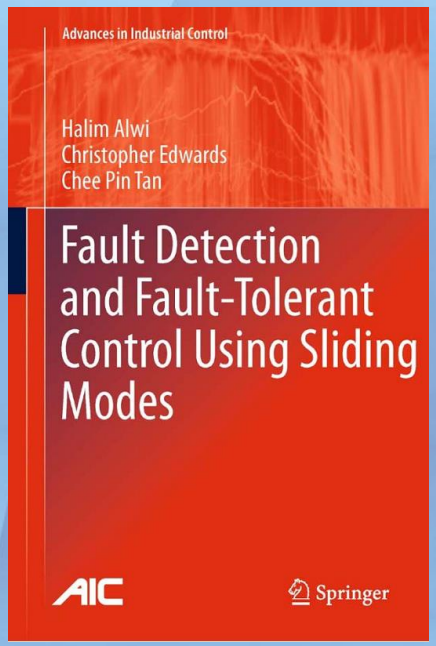
# مراجع و منابع

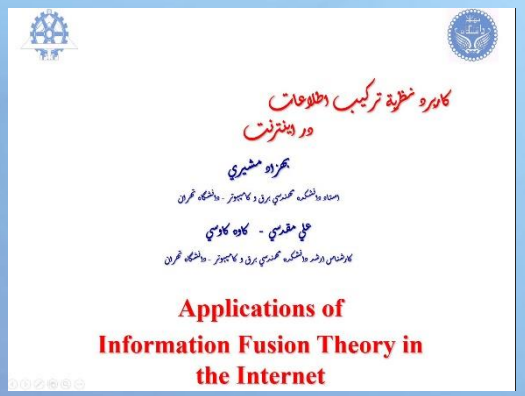

Rolf Isermann
Fault-Diagnosis Applications
Model-based condition monitoring: Actuators, drives, machinery, plants, sensors, and fault-tolerant systems
Springer


R. Isermann
Fault-Diagnosis Systems
An Introduction from Fault Detection to Fault Tolerance
Springer


INTELLIGENT FAULT DIAGNOSIS AND REMAINING USEFUL LIFE PREDICTION OF ROTATING MACHINERY
Yaguo Lei


L.H. Chiang, E.L. Russell and R.D. Braatz
Fault Detection and Diagnosis in Industrial Systems
ADVANCED TEXTBOOKS IN CONTROL AND SIGNAL PROCESSING
Springer


Advances in Industrial Control
Halim Alwi
Christopher Edwards
Chee Pin Tan
Fault Detection and Fault-Tolerant Control Using Sliding Modes
AIC
Springer


کاربرد نظریهٔ ترکیب اطلاعات در اینترنت
Applications of Information Fusion Theory in the Internet