



ارائه شده توسط :

سایت ترجمه فا

مرجع جدیدترین مقالات ترجمه شده

از نشریات معابر

پیش بینی غلظت هیدروژن در مهار حوادث شدید با استفاده از شبکه

عصبی فازی

چکیده

اخیرا، حوادث شدیدی در نیروگاه های هسته ای (NPP ها) یک نگرانی جهانی شده است. هدف این مقاله پیش بینی ساخت هیدروژن داخل درون داره نیروگاه ناشی از حوادث شدید می باشد. این پیشگویی براساس NPP های یک راکتور نیروگاه بهینه سازی شده 1000 بوده است. افزایش غلظت هیدروژن در حوادث شدید یکی از عوامل اصلی است که انسجام درون داره را تهدید می کند. یک روش با استفاده از شبکه عصبی فازی یا FNN برای پیشگویی غلظت هیدروژن داخل درون داره بکار بسته شد. مدل FNN تدوین گردید و براساس داده های شبیه سازی شده بدست آمده با شبیه سازی کد MAAP4 برای راکتور نیروگاه بهینه سازی 1000 روایی سازی گردید. مدل FNN بنا به انتظار به اپراتورها برای پیشگیری از انفجار هیدروژن در موقعیت های حوادث شدید کمک می کند و حادثه را به طور مناسبی مدیریت می کند چون قادر به پیشگویی تغییرات در روند غلظت هیدروژن در آغاز رویدادهای واقعی با استفاده از مدل FNN تدوین شده می باشد.

کلیدواژه ها: سیستم استنباط فازی، شبکه عصبی فازی، الگوریتم ژنتیکی، غلظت هیدروژن، حادثه از بین رفتن سردن، حادثه شدید

۱- مقدمه

اخیرا، حوادث شدید نیروگاه های هسته ای یا NPP ها یک نگرانی جهانی شده است. در رویداد حوادث شدید، پارامترهای ایمنی اصلی راکتورهای هسته ای به سرعت طی مراحل اولیه تغییر کرده و برای اپراتورها زمان ناکافی برای ابداع یک پاسخ مناسب برجای می گذارد. مدیریت کارامد یک حادثه جدی نیازمند مشاهده پارامترهای کلیدی طی طول دوره خیلی مختصر رویدادهای اولیه با تعیین سناریوها و رویدادهای اولیه ای است که منجر به این حادثه می شود. بویژه، فوق العاده مهم است که پارامترهای مرتبط با ایمنی و اطلاعات حیاتی را طی دوره فوق العاده کوتاه بعد از حادثه از دست دادن سردن، LOCA و خرایی لوله ژنراتور بخار یا SGTR تعیین نمود. این کار تایید وضعیت NPP و تعیین عملکرد تصحیح کننده مناسب را قادر می سازد.

در صورت حوادث شدید، اپراتورهای NPP درباره انفجار هیدروژن به دلیل تجمع هیدروژن در درون داره نگرانند.

هیدروژن در درون داره با تراوش از مرز فشار اولیه تجمع می یابد.

ازینرو، این کار حوادث شدیدی را درنظر گرفته که توسط LOCAها ایجاد شده که با استفاده از داده های حاصل از راکتور نیروی بهینه 1000 یا OPR1000 تحلیل گردیده است. این کار با هدف پیشگویی غلظت هیدروژن در رویداد یک حادثه شدید صورت گرفت. افزایش در غلظت هیدروژن یکی از عوامل تهدید کننده انسجام درون داره است. هیدروژن داخل درون داره با رادیواکتیوسازی آب موجود در جو، فرسایش ماده داخلی درون داره توسط اسپری درون داره، و واکنش بخار با روکش آبکاری شده زیروکونیوم تولید می شود. حفظ انسجام درون داره با پیشگیری از انفجار هیدروژن درونی نیاز به این دارد که غلظت هیدروژن زیر 4 درصد نگه داشته شود.

از این مطالعه، انواع روشهای هوش مصنوعی یا AI برای پیشگویی تغییرات در غلظت هیدروژن بررسی گردید. تعیین گردیده که یک روش با استفاده از یک شبکه عصبی فازی یا FNN مناسب ترین نوع برای پیشگویی غلظت هیدروژن بوده است. یک تعداد تکنیک های AI به طور موفقیت آمیزی برای انواع عرصه های تحقیقاتی مهندسی هسته ای، مانند روایی سازی سیگنال، تشخیص کارخانه، شناسایی رویداد، و حسگر هوشمند (یا تخمین عملکر) بکار بسته شده است. بسیاری از کارهای قبلی با استفاده از سیستم استنباطی فازی یا FIS و شبکه های عصبی یا NN ها بوده است. Jang & Sun تعادل عملیاتی میان NNها و FISها را در مواردی نشان داده اند که توابع فعالسازی NNها و تابع عضویت FIS یکسان بوده اند.

یک FNN یک مدل مبتنی بر داده هاست که نیازمند داده ها برای تدوین و تایید آن است. چون داده های حوادث شدید واقعی در دست نیست، لازم است از شبیه سازی های عددی برای کسب داده های لازم برای مدل مطرح شده استفاده کنیم. مدل FNN براساس داده های شبیه سازی NPP که استفاده از کد MAPP4 را ملزم می سازد تایید شده است. مدیریت موفقیت آمیز NPPها در نتیجه توانایی پیشگویی سریع پارامترهای حیاتی - ایمنی طی حوادث واقعی می تواند منجر به حفاظت از NPPها گردد.

2-شبکه عصبی فازی

تئوری فازی در تلاشی برای استفاده از یک رهیافت ریاضی برای اثبات عدم صحت در افکار و اعمال انسان مطالعه گردیده است. FIS براساس مفاهیم یادگیری و استنباط هوشمند ایجاد شده است. یک مدل FNN شامل یک FIS در ترکیب با سیستم آموزش عصبی آن می باشد.

1-2-سیستم استنباط فازی

عموما از قوانین مشروطی استفاده می کند که متشکل از قوانین اگر/آنگاه بخش مقدم و بخش منتج است و یکی از روش‌های AI می باشد. هر دو بخش‌های مقدم و منتج توابع عضویت می باشند که قادر به فازی سازی مقادیر ناچیز می باشد. در بیشتر موارد، تابع گاووسی، مثلثی، ذوزنقه ای، و زنگوله ای اشکل در فرمولهای توابع عضویت بکار می رود.

شکل 1 یک تصویری را از طرح کلی اصول FIS نشان می دهد. خروجی FIS باید یک مقدار حقیقی باشد که نیاز به فازی زدایی قبل از تشکیل خروجی FIS دارد. با استفاده از FIS از نوع Takagi-Sugeno که نیازی به فازی زدایی ندارد، یک قانون آم اختیاری را می توان به ترتیب ذیل در معادله 17 بیان نمود:

$$\text{If } x_1(k) \text{ is } A_{i1}(k) \text{ AND } \dots \text{ AND } x_m(k) \text{ is } A_{im}(k), \text{ then} \\ \hat{y}_i(k) \text{ is } f_i[x_1(k), \dots, x_m(k)] \quad (1)$$

که در آن $x_j(k)$ متغیر ورودی برای مدل استنباط فازی بوده است ($j = 1, 2, \dots, m$)، m تعداد متغیرهای ورودی است)، $A_{ij}(k)$ تابع عضویت متغیر ورودی j برای قانون فازی آم بوده است ($i = 1, 2, \dots, n$ ، n تعداد قوانین می باشد)، و $\hat{y}_i(k)$ خروجی قانون فازی آم می باشد. در معادله شماره 1، تابع $f_i[x_1(k), \dots, x_m(k)]$ نمایانگر یک تابع از متغیرهای ورودی است. تابع عضویت مجموعه های فازی A_{i1}, \dots, A_{im} برای قانون فازی آم

به ترتیب به شکل $\alpha_{i1}(x_1), \dots, \alpha_{im}(x_m)$ نشانگذاری شده است.

تعداد N داده های آموزشی ورودی و خروجی مدل فازی $\mathbf{z}^T(k) = [\mathbf{x}^T(k), y(k)]$ (که در آن $k = 1, 2, \dots, N$) مفروض شد که موجود است و نقطه داده در هر بعد نرمالسازی گردید. یک تابع عضویت گاووسی به دلیل توانایی این تابع به کاهش تعداد پارامترهای

بهینه سازی شده بکار گرفته شد. با استفاده از FIS از نوع Takagi-Sugeno، خروجی FIS می تواند به شکل ذیل بیان گردد:

$$\hat{y}(k) = \sum_{i=1}^n y_{wi}(k) \quad (2)$$

که در آن

$$y_{wi}(k) = \bar{w}_i(k) f_i[\mathbf{x}(k)] \quad (3)$$

$$\bar{w}_i(k) = \frac{w_i(x(k))}{\sum_{i=1}^n w_i(x(k))} \quad (4)$$

$$w_i(k) = \prod_{j=1}^m \alpha_{ij}(x_j(k)) \quad (5)$$

$$\alpha_{ij}(x_j(k)) = e^{-\frac{(x_j(k) - c_{ij})^2}{2s_{ij}^2}} \quad (6)$$

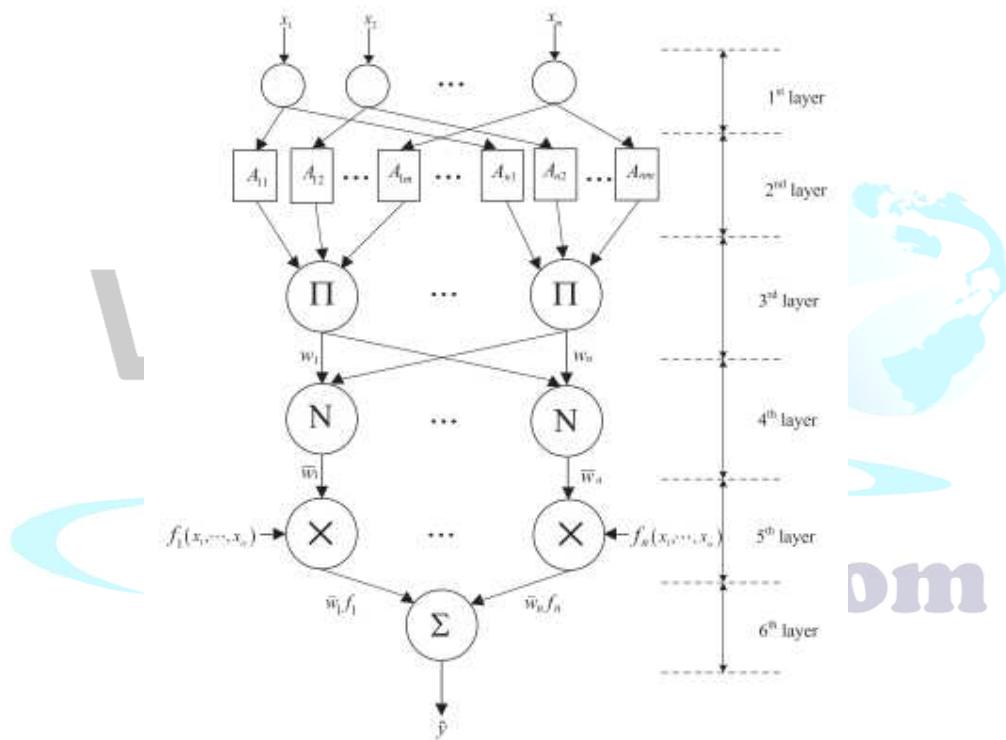
در معادله 3، تابع $f_i[\mathbf{x}(k)]$ به شکل چندجمله ای از رده اول متغیرهای ورودی قانون فازی آم و خروجی هر قانون به شکل ذیل بیان می گردد:

$$f_i[\mathbf{x}(k)] = \sum_{j=1}^m \beta_{ij} x_j(k) + b_i \quad (7)$$

که در آن β_{ij} وزن قانون فازی آم و متغیر ورودی j ام می باشد، و b_i سوگیری قانون فازی آم می باشد. از اینرو، در این مورد FIS را به شکل FIS از رده اول با نوع Takagi-Sugeno می نامند، چون خروجی قانون فازی آم می باشد، f_i یک مقدار حقیقی است و به شکل چندجمله ای رده اول برای ورودی ها بیان می گردد. شکل 2 نشان دهنده عملیات محاسبه FIS می باشد. اولین لایه نشان دهنده گره های ورودی است که مستقیما را مقادیر ورودی را به لایه بعدی انتقال می دهد.



شکل ۱- سیستم استنباطی فازی (از نوع Mamdani)



شکل ۲- شبکه عصبی فازی

هر خروجی از اولین لایه با تابع عضویت جانشین می‌گردد. دومین لایه نشان دهنده یک لایه فازی سازی است که هدف تبدیل یک مقدار ورودی ناچیز به یک مقدار فازی است. سومین لایه نشان دهنده یک اپراتور حاصل روی توابع عضویت می‌باشد که به شکل معادله ۵ بیان گردیده است. چهارمین لایه یک عملیات نرمالسازی را اجرا می‌کند که به شکل معادله ۴ بیان گردیده است. پنجمین لایه خروجی هر قانون فازی اگر/آنگاه را ایجاد می‌کند. سرانجام اینکه ششمین لایه یک تجمع کلیه قوانین فازی اگر/آنگاه را اجرا می‌کند و به شکل معادله ۲ بیان می‌گردد.

از اینرو، خروجی FIS بنا به معادله 2 می تواند به این صورت نوشته شود:

$$\hat{y}(k) = \chi(k)^T \omega \quad (8)$$

که در آن

$$\omega = [\beta_{11} \cdots \beta_{n1} \cdots \cdots \beta_{1m} \cdots \beta_{nm} \ b_1 \cdots b_n]^T$$

و

$$\chi(k) = [\bar{w}_1(k)x_1(k) \cdots \bar{w}_n(k)x_1(k) \cdots \bar{w}_1(k)x_m(k) \cdots \bar{w}_n(k)x_m(k) \cdots \bar{w}_1(k) \cdots x_n(k)]^T$$

برای یک سری از N جفت داده های ورودی/خروجی، معادله ذیل از معادله 8 مشتق گردیده است:

$$\hat{y} = \mathbf{x}\omega \quad (9)$$

که در آن:

$$\hat{y} = [\hat{y}(1) \hat{y}(2) \cdots \hat{y}(N)]^T$$



و

$$\mathbf{x} = [\chi(1) \chi(2) \cdots \chi(N)]^T.$$

بردار ω به شکل بردار پارامتر منتج اشاره گردیده و ماتریس \mathbf{x} شامل داده های ورودی و مقادیرتابع عضویت می باشد. مقادیر خروجی FIS در یک ماتریس $N \times (m+1)n$ با ابعاد $N \times (m+1)n$ و یک بردار پارامتر ω با ابعاد $(m+1)n$ بیان گردیده است.

FIS 2-آموزش

پارامترهای مقدم مرتبط با توابع عضویت معادله 6 با استفاده از یک الگوریتم ژنتیکی بهینه سازی گردید و پارامترهای منتج گنجانده شده در معادله 7 با استفاده از یک روش حداقل مربعات بهینه سازی گردید. در الگوریتم های ژنتیکی، متغیرهای لازم برای بهینه سازی درون کروموزوم کدگذاری شده و برتری درباره هر کروموزوم تحت قضاوت با تابع تناسب است.

در این مطالعه، داده های آموزشی برای بهینه سازی پارامترهای مدل FNN بکار گرفته شد. داده های تست برای تایید مدل تدوین شده استفاده گردید و متفاوت از مجموعه داده هایی است که برای آموزش استفاده شده است.

تابع تناسب در معادله ذیل تمایل به حداقل سازی خطای مربع میانگین ریشه RMS و حداقل خطا دارد:

$$F = \exp(-\mu_1 E_1 - \mu_2 E_2). \quad (10)$$

که در آن

$$E_1 = \sqrt{\frac{1}{N} \sum_{k=1}^{N_t} (y(k) - \hat{y}(k))^2}, \quad E_2 = \max_k (y(k) - \hat{y}(k)), \quad N_t$$

تعداد مقادیر داده های آموزشی است، E_1 یک خطای RMS می باشد و E_2 یک خطای ماکزیمم می باشد. متغیر

نشان دهنده مقدار هدف واقعی است در صورتیکه $\hat{y}(k)$ مقدار منطبقه ای است که با استفاده از مدل FNN

پیشگویی می شود. اگر پارامترهای قبلی با الگوریتم ژنتیکی تثبیت می شوند، ماتریس $\mathbf{\chi}$ بالواقع در خروجی های

مدل مطرح شده FNN بیان شده با معادله 9 تعیین می شد. از اینرو، روش حداقل مربعات برای تعیین پارامتر

منتج ω قوانین فازی استفاده گردید. پارامتر منتج ω برای حداقل سازی تابع هدف انتخاب گردید که شامل

خطای مربع بین مقدار هدف $y(k)$ و مقدار پیشگویی شده اش $\hat{y}(k)$ می باشد و به ترتیب ذیل بیان گردیده است:

TarjomeFa.Com

$$\begin{aligned} J &= \frac{1}{2} \sum_{k=1}^{N_t} (y(k) - \hat{y}(k))^2 = \frac{1}{2} \sum_{k=1}^{N_t} (y(k) - \mathbf{\chi}(k)^T \boldsymbol{\omega})^2 \\ &= \frac{1}{2} (\mathbf{y}_t - \hat{\mathbf{y}}_t)^T (\mathbf{y}_t - \hat{\mathbf{y}}_t) \end{aligned} \quad (11)$$

که در آن

$$\mathbf{y}_t = [y(1) \ y(2) \cdots y(N_t)]^T$$

و

$$\hat{\mathbf{y}}_t = [\hat{y}(1) \ \hat{y}(2) \cdots \hat{y}(N_t)]^T.$$

یک راه حل برای حداقل سازی تابع هدف فوق می تواند با استفاده از معادله ذیل بدست آید:

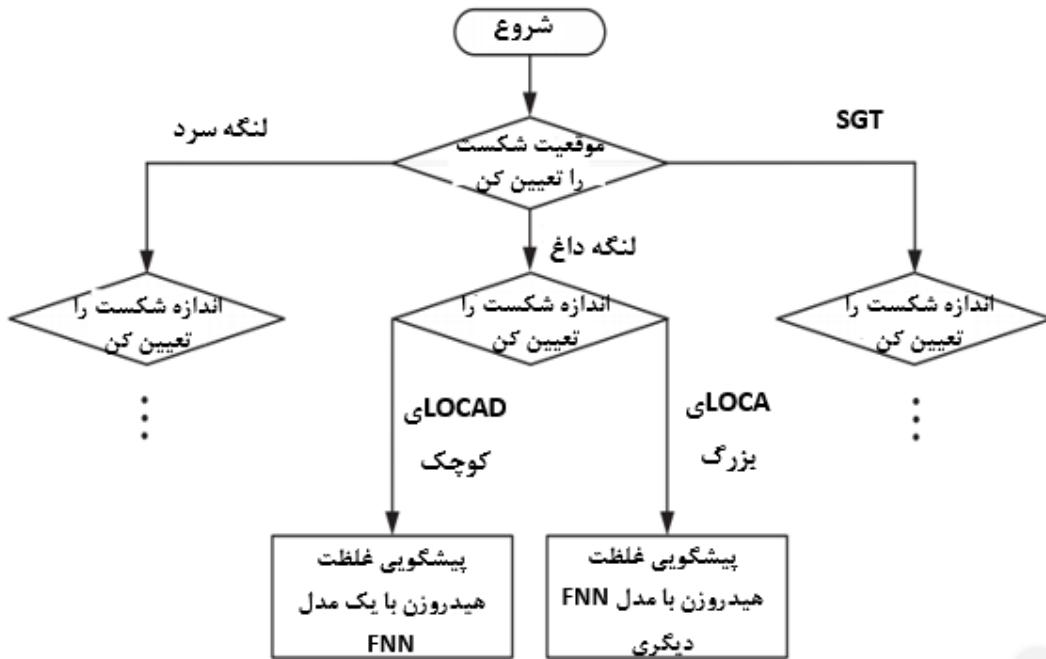
$$\mathbf{y}_t = \mathbf{x}_t \boldsymbol{\omega}$$

(12)

که در آن

$$\mathbf{x}_t = [\chi(1) \chi(2) \cdots \chi(N_t)]^T.$$

ماتریس \mathbf{x}_t دارای $N_t \times (m+1)n$ بعد می باشد و برای حل بردار پارامتر $\boldsymbol{\omega}$ ، معکوس ماتریس \mathbf{x}_t باید وجود داشته باشد. بر عکس، به طور کلی، \mathbf{x}_t یک ماتریس وارونه ندارد چون معمولاً ماتریس \mathbf{x}_t یک ماتریس مرتب نیست.



شکل 3-پیشگویی غلظت هیدروژن با استفاده از شش مدل شبکه عصبی فازی منسجم یا FNN
بنابراین، کاذب معکوس ماتریس \mathbf{x}_t بکار گرفته شد. بردار پارامتر $\boldsymbol{\omega}$ به سهولت با استفاده از ماتریس کاذب معکوس بنا به مورد ذیل حل می شود.

$$\boldsymbol{\omega} = (\mathbf{x}_t^T \mathbf{x}_t)^{-1} \mathbf{x}_t^T \mathbf{y}_t \quad (13)$$

یعنی بردار پارامتر $\boldsymbol{\omega}$ می تواند از سری های جفت های داده های ورودی و خروجی محاسبه گردد.

3-آماده سازی داده ها

مدل FNN مطرح شده متعاقبا برای پیشگویی غلظت هیدروژن در درون داره با تراوش از مرز فشار اولیه، انواع شبیه سازی های LOCA انجام گردید. مفروض بوده است که سیستم های ایمنی از جمله سیستم های تزریق ایمنی فعال مدلسازی LOCA را موجب گردیده که به حادث شدید پیشرفت می کند که باعث صدمه اساسی می شود و تولید هیدروژن را تسريع می سازد. مدل FNN دو سیگنال ورودی را به نام مقدار پیشگویی شده اندازه شکست LOCA و زمان سپری شده بعد از بسته شدن راکتور بکار برده است.داده های آموزشی و تست برای مدل مطرح شده با شبیه سازی سناریوهای حادثه شدید با استفاده از کد OPR1000 برای MAAP4 کسب گردید. داده های استفاده شده از نتایج شبیه سازی غلظت هیدروژن بر حسب زمان است.

در این مطالعه، شبیه سازی های عددی با استفاده از کد برای انواع موقعیت های شکست و اندازه شکست LOCA اجرا گردید. موقعیت شکست LOCA به قسمتهای لنگه داغ، لنگه سرد، و لوله ژنراتور بخار تقسیم بندی گردید و مراحل اندازه شکست به 210 مرحله تقسیم گردید. اندازه های شکست از 1/10000 یک شکست ماشین آهنبری با انتهای دوبل تا نیمی از یک شکست ماشین آهنبری با انتهای دوبل برای لنگه داغ و لنگه سرد LOCA ها می رسد، و اندازه های شکست از 1 تا 210 خرابی های لوله برای حوادث SGTR می رسد.

حوادث دربردارنده LOCAها نیاز به شناسایی و پیشگویی موقعیت LOCA و اندازه شکست دارد چون این مقادیر شناسایی نشده است. از اینرو، سیگنال اندازه شکست LOCA که یک سیگنال ورودی برای مدل FNN می باشد، از مطالعات قبلی بدست آمد که در آن الگوریتم ها برای هدف تعیین این سیگنال تدوین گردیدند. این مطالعات نیز تعیین نمود که امکانپذیر است اندازه شکست LOCA را به طور صحیح با یک خطای RMS حدود 0.4% پیشگویی نمود. به همین دلیل، اندازه شکست LOCA می تواند به عنوان یک متغیر ورودی برای پیشگویی غلظت هیدروژن داخل درون داره استفاده شود.

شبیه سازی منجر به 630 مورد سناریوهای حادثه شدید گردید. داده ها شامل 210 قسمت برای هر یک از LOCA های لنگه داغ، با لنگه سرد و SGTR بود.

4- کاربرد برای پیشگویی غلظت هیدروژن

در رویداد یک حادثه شدید، لازم است که بررسی شود آیا غلظت هیدروژن در درون داره اضافی است یا خیر.

متغیرهای ورودی برای پیشگویی غلظت هیدروژن عبارتند از زمان سپری شده بعد از بسته شدن راکتور و اندازه

شکست LOCA پیشگویی شده.

جدول 1-عملکرد مدل شبکه عصبی فازی (حادثه از دست رفتن سردکن لنگه داغ یا LOCA)

تعداد قوانین فازی	کوچک LOCA				بزرگ LOCA				کلیه اندازه شکست	
	داده های آموزشی		داده های تست		داده های آموزشی		داده های تست		داده های تست	
	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)
5	16.92	118.00	20.81	108.19	0.86	17.08	1.18	6.18	11.14	108.19
10	8.70	65.04	8.10	36.83	0.86	17.82	1.21	7.20	2.68	21.89
30	6.97	69.87	5.18	21.85	0.66	16.19	0.94	6.67	1.83	13.29
50	5.80	62.61	5.87	33.11	0.60	14.92	0.82	6.37	3.65	33.11

RMS، میانگین مربعات ریشه

مقادیر به فونت مشکی داده های بهینه شده ترین مقادیر می باشند.

جدول 2-عملکرد مدل شبکه عصبی فازی (حادثه از دست رفتن سردکن لنگه سرد یا LOCA)

تعداد قوانین فازی	کوچک LOCA				بزرگ LOCA				کلیه اندازه شکست	
	داده های آموزشی		داده های تست		داده های آموزشی		داده های تست		داده های تست	
	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)
5	8.51	72.30	12.13	45.36	2.62	28.89	3.42	12.90	7.35	43.31
10	6.29	68.11	9.43	43.24	2.34	20.47	3.00	7.87	5.57	43.24
30	5.19	63.24	7.81	39.30	2.04	19.07	2.73	9.97	4.98	37.59
50	4.56	67.32	8.09	55.07	1.96	18.58	2.71	9.46	6.36	55.07

RMS، میانگین مربعات ریشه

جدول 3-عملکرد مدل شبکه عصبی فازی (شکست لوله ژنراتور بخار)

تعداد قوانین فازی	کوچک LOCA				بزرگ LOCA				کلیه اندازه شکست	
	داده های آموزشی		داده های تست		داده های آموزشی		داده های تست		داده های تست	
	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)	خطای (/.)RMS	خطای ماکریم (/.)
5	8.51	72.30	12.13	45.36	2.62	28.89	3.42	12.90	7.35	43.31
10	6.29	68.11	9.43	43.24	2.34	20.47	3.00	7.87	5.57	43.24
30	5.19	63.24	7.81	39.30	2.04	19.07	2.73	9.97	4.98	37.59
50	4.56	67.32	8.09	55.07	1.96	18.58	2.71	9.46	6.36	55.07

	(/.)RMS	ماکزیمم (%)								
5	11.92	70.39	36.62	41.85	14.25	74.58	19.84	61.79	18.66	61.79
10	11.92	62.50	15.83	40.32	13.57	72.42	20.79	67.72	18.19	52.35
30	11.03	70.12	14.27	43.10	11.07	97.44	15.75	46.09	14.93	46.09
50	10.12	77.83	12.58	30.94	10.58	110.27	14.57	50.00	13.41	45.28

LOCA، حادثه از دست رفتن سردکن؛ RMS، میانگین مربعات ریشه

از اینرو، مدل‌های FNN تدوین گردید تا هر دو LOCA‌های شکست بزرگ و کوچک و موقعیت شکست را ارزیابی کند. مدل‌های FNN با هر دو الگوریتم ژنتیکی و هم روش حداقل مربعات بهینه سازی گردید.

شکل 3 نشان دهنده شش مدل منسجم FNN (که هر یک شامل 3 موقعیت شکست بوده که هر یک به دو گروه اندازه شکست تقسیم بندی شده اند) که در این مطالعه برای پیشگویی غلظت هیدروژن تدوین گردید. وانگهی، سه نوع مختلف مدل‌های FNN طبق موقعیت LOCA تدوین گردید که نامش لنگه داغ و لنگه سرد و SGTR بود. به علاوه دو نوع متفاوت مدل‌های FNN بسته به اینکه ایا اندازه شکست LOCA کوچک یا بزرگ می‌باشد، تدوین گردید. در مورد LOCA‌های لنگه داغ و لنگه سرد، اندازه‌های شکست در هر یک از این‌ها باز به دو گروه تقسیم می‌شود که دارای 30 اندازه شکست کوچکتر تشکیل دهنده یک گروه است و بقیه 180 اندازه شکست تشکیل دهنده گروه دیگری می‌باشد.

جدول 4- عملکرد مدل شبکه عصبی فازی با فرض خطای پیشگویی اندازه شکست حادثه از دست رفتن سرد کن یا LOCA (خطای پیشگویی میانگین کمتر از 5 درصد)

تعداد قوانین فازی	ای لنگه داغ LOCA		ای لنگه سرد LOCA		SGTR	
	داده های آموزشی		داده های آموزشی		داده های تست	
	خطای RMS (%)	ماکزیمم (%)	خطای RMS (%)	ماکزیمم (%)	خطای RMS (%)	ماکزیمم (%)
5	11.70	113.88	7.36	43.21	19.01	61.06
10	2.62	20.89	5.48	41.90	18.75	51.20
30	1.78	12.76	4.96	36.23	17.45	71.88
50	3.93	35.99	6.33	54.21	15.50	56.67

RMS، میانگین مربعات ریشه؛ SGTR، شکست لوله ژنراتور بخار

جدول 5- عملکرد مدل شبکه عصبی فازی با فرض خطای پیشگویی اندازه شکست حادثه از دست رفتن سرد کن یا LOCA (خطای پیشگویی میانگین بیش از 5 درصد)

تعداد قوانین فازی	LOCA ای لنگه داغ		LOCA ای لنگه سرد		SGTR	
	داده های آموزشی		داده های آموزشی		داده های تست	
	خطای خطای (/.) RMS	خطای ماکریم (/.) RMS	خطای خطای (/.) RMS	خطای ماکریم (/.) RMS	خطای خطای (/.) RMS	خطای ماکریم (/.) RMS
5	10.16	98.14	7.56	43.48	19.49	58.79
10	2.88	23.13	5.87	44.79	23.20	96.53
30	2.53	14.00	5.26	39.24	24.71	99.15
50	6.97	53.72	6.46	56.04	435.05	4.34×10^3

RMS، میانگین مربعات ریشه؛ SGTR، شکست لوله ژنراتور بخار

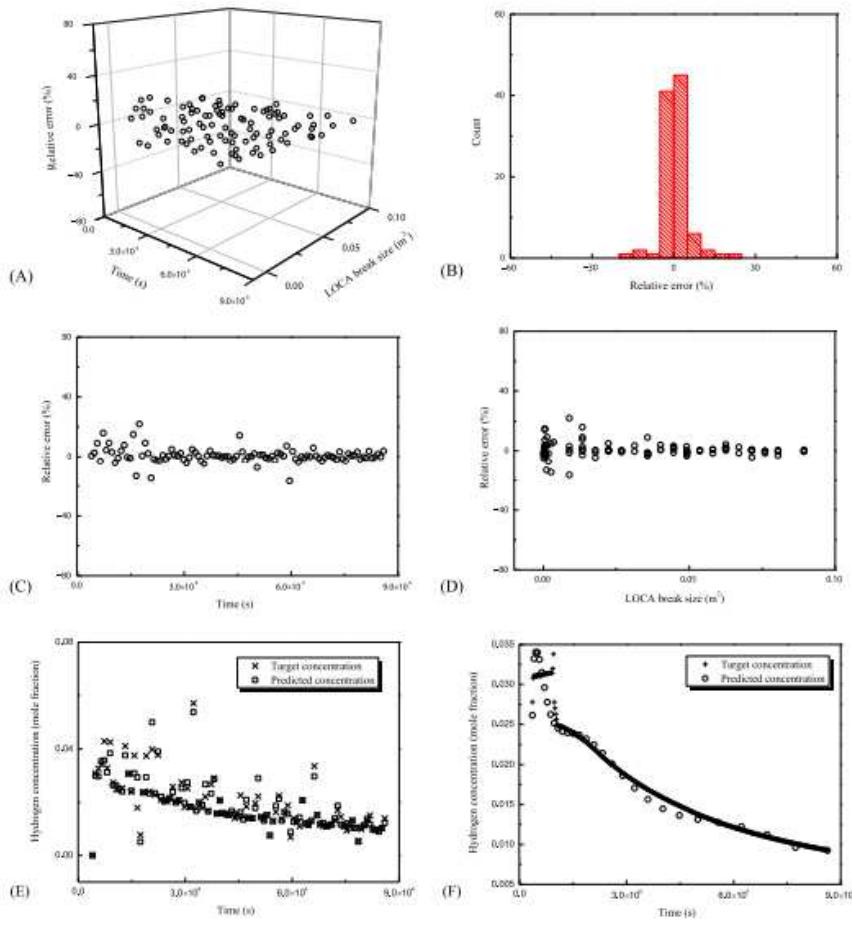
مشابهها، در مورد SGTR، اندازه های شکست نیز به دو گروه تقسیم بندی گردید: 100 اندازه های شکست کوچکتر با هم گروه بندی گردید حین اینکه 110 تا باقیمانده از اندازه های شکست بزرگتر، گروه دوم را تشکیل داد. دلیل اینکه دو گروه بکار رفته این بوده که این گروه بندی نتایج بهتری را نسبت به آنی که از تنها یک گروه استفاده کرده است، فراهم کرده است.

داده های تست متفاوت از داده های استفاده شده برای تدوین مدل FNN بود و شامل زمان سپری شده بعد از بسته شدن راکتور، اندازه شکست پیشگویی شده LOCA، و غلظت هیدروژن بوده است. برای این مطالعه، 100 نقطه داده برای هر یک از موقعیت های شکست LOCA به نام LOCA ای لنگه داغ و لنگه سرد و SGTR به عنوان نقاط داده های تست انتخاب گردید.

مقادیر پارامتری که مرتبط با الگوریتم ژنتیکی است و FIS به ترتیب ذیل می باشد: احتمال کراس اور برابر 100 درصد بوده، احتمال موتاسیون برابر 5 درصد است و اندازه جمعیت 20 می باشد.

جدول 3-1 نشان دهنده نتایج عملکردی است که با مدل تدوین شده FNN برای سه موقعیت شکست به ترتیب لنگه داغ، لنگه سرد و SGTR بدست آمدند.

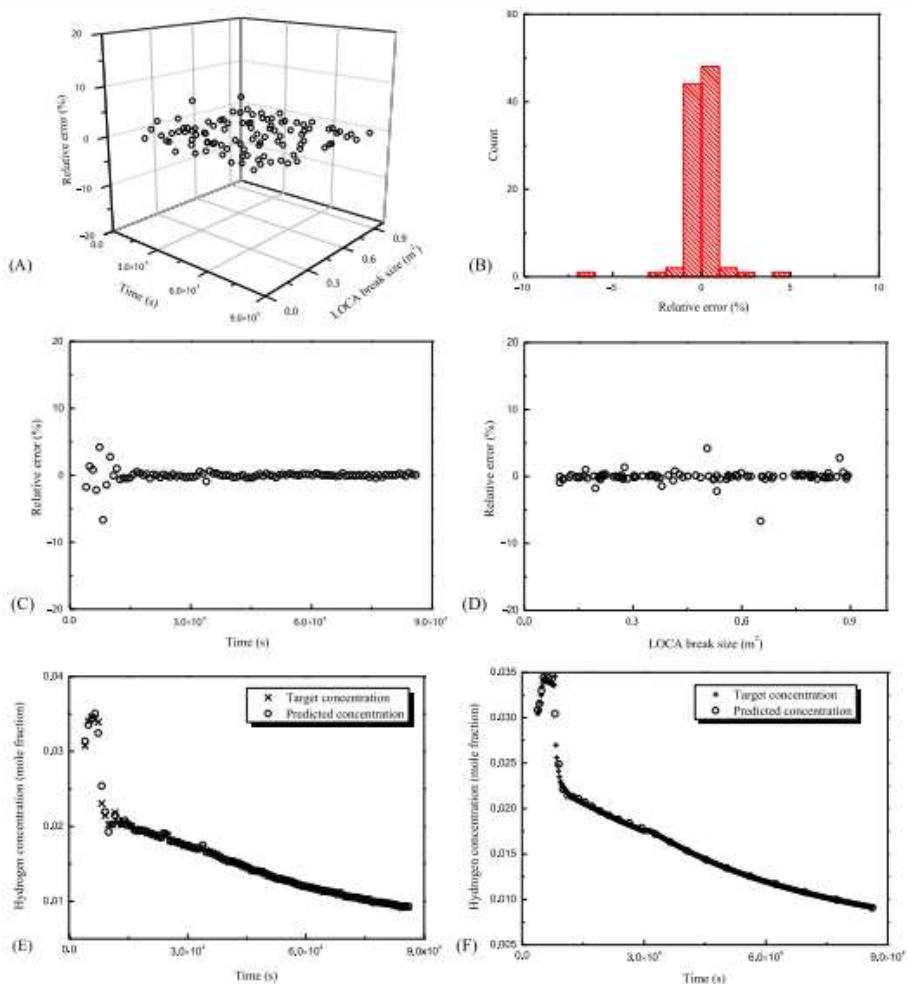
شکل 4-عملکرد پیشگویی مدل شبکه عصبی فازی در حادثه از دست رفتمن سردکننده کوچک لنگه داغ یا LOCA . (A) خطای پیشگویی نسبی غلظت هیدروژن بر حسب زمان سپری شده و اندازه شکست حادثه از دست دادن سردکن. (B) هیستوگرام خطای پیشگویی نسبی غلظت هیدروژن. (C) خطای پیشگویی نسبی غلظت هیدروژن بر حسب زمان سپری شده. (D) خطای پیشگویی نسبی غلظت هیدروژن بر حسب اندازه شکست LOCA . (E) غلظت هیدروژن بر حسب زمان. (F) غلظت هیدروژن بر حسب زمان در یک اندازه شکست LOCA ای خاص.



برای داده های تست LOCA ای لنگه داغ، خطاهای RMS تقریبا 11.14% ، 2.68% ، 1.83% و 3.65% برای مدل FNN با پنج، 10، 30 و 50 قانون فازی به ترتیب بوده است. برای داده های تست LOCA ای لنگه سرد، خطاهای RMS تقریبا 7.35% ، 5.57% ، 4.98% و 6.36% برای مدل FNN و 5 و 10 و 30 و 50 قانون فازی به ترتیب بوده است. باز، برای داده های تست SGTR، خطاهای RMS تقریبا 18.66% ، 18.19% ، 14.93% و 13.41% به ترتیب بوده است. بنابراین، مدل FNN با 30 قانون فازی بنا به اثبات صحیح ترین برای پیشگویی غلظت هیدروژن در هر دو LOCA ای لنگه داغ و لنگه سرد می باشد، در حالیکه مدل FNN با 50 قانون فازی مشخص گردید که صحیح ترین برای پیشگویی غلظت هیدروژن در SGTR می باشد.

شکل 5-عملکرد پیشگویی مدل شبکه عصبی فازی در حادثه از دست رفتن سردکننده بزرگ لنگه داغ یا LOCA . (A) خطای پیشگویی نسبی غلظت هیدروژن بر حسب زمان سپری شده و اندازه شکست حادثه از دست دادن

سردکن. B) هیستوگرام خطای پیشگویی نسبی غلظت هیدروژن. C) خطای پیشگویی نسبی غلظت هیدروژن بر حسب زمان سپری شده. D) خطای پیشگویی نسبی غلظت هیدروژن بر حسب اندازه شکست LOCA. E) غلظت هیدروژن بر حسب زمان در یک اندازه شکست LOCA ای خاص.



جدول 6-عملکرد مدل‌های بهینه سازی شده شبکه عصبی فازی

موقعیت شکست	خطای پیشگویی اندازه شکست LOCA عدم		خطای پیشگویی اندازه شکست عدم LOCA تصادفی زیر 5 درصد		خطای پیشگویی اندازه شکست LOCA بیش از 5 درصد	
	خطای RMS (%)	خطای ماکریم (%)	خطای RMS (%)	خطای ماکریم (%)	خطای RMS (%)	خطای ماکریم (%)
LOCA ای لنگه داغ	1.83	13.29	1.78	12.76	2.53	14.00
LOCA ای لنگه سرد	4.98	37.59	4.96	36.23	5.26	39.24
SGTR	18.66	61.79	19.01	61.06	19.49	58.79

LOCA، حادثه از دست دادن سرد کن؛ RMS، میانگین مربعات ریشه؛ SGTR، شکست لوله ژنراتوربخار

قبله، اندازه شکست LOCA می توانست به طور صحیح در عرض 60 ثانیه بعد از بسته شدن راکتور با یک خطای حدود 0.4% پیشگویی گردد. اما، لازم است که روی اثر انتشار خطا تحقیق شود که در اثر خطاهای سیگنالهای ورودی می باشد، حتی اگر کوچک باشند. جدول 4 عملکرد مدل‌های FNN را در موردی نشان داده است که در آن اندازه شکست LOCA بنا به فرض با یک خطای تصادفی کمتر از 5 درصد پیشگویی می گردد. در این مورد، تجزیه عملکرد مدل‌های FNN ناشی از وجود خطاهای ورودی مشهود نیست. جدول 5 نشان دهنده عملکرد مدل‌های FNN در موردی است که اندازه شکست LOCA بنا به فرض دارای یک خطای پیشگویی 5 درصدی باشد. در مورد SGTR، مدل FNN با 50 قانون فازی مشخص گردید که دارای یک مشخصات تناسب بیش از حد بوده در صورتیکه مدل FNN با 5 قانون فازی مشخص گردید که به بهترین نحو عمل می کند.

شکل 4 و 5 غلظت هیدروژن پیشگویی شده را با مدل‌های FNN بهینه سازی شده همراه با خطاهای پیشگویی شان برای داده های تست LOCA های لنگه داغ کوچک و لنگه داغ بزرگ به ترتیب نشان می دهد. شکلهای 4a و 5a خطاهای پیشگویی غلظت هیدروژن را بر حسب زمان سپری شده و اندازه شکست LOCA برای LOCA کوچک و بزرگ لنگه داغ به ترتیب نشان می دهد. شکل 4b و 5b نشاندهنده هیستوگرام خطای پیشگویی است که برای تایید توزیع خطای غلظت هیدروژن استفاده گردید. شکلهای 4c و 5c خطاهای پیشگویی غلظت هیدروژن را بر حسب زمان سپری شده نشان می دهد. شکلهای 4d و 5d نشاندهنده خطاهای پیشگویی غلظت هیدروژن بر حسب زمان سپری شده است. شکلهای 4d و 5d خطاهای پیشگویی غلظت هیدروژن را بر حسب اندازه شکست نشان می دهد. شکلهای 4e و 5e غلظت هیدروژن را بر حسب زمان سپری شده نشان می دهد. داده های غلظت هیدروژن به دلیل اندازه های شکست متفاوت LOCA که موجود بوده، پراکنده اند. شکلهای 4f و 5f غلظت هیدروژن را بر حسب زمان سپری شده در اندازه شکست LOCA ای خاصی نشان می دهد. منحنی های منطبقه مرتبط با LOCA و SGTR لنگه سرد روندهای مشابهی را نشان دادند و از این مقاله به دلیل کمبود فضا حذف گردیدند.

جدول 6 نشان دهنده عملکرد مدل‌های FNN بهینه سازی شده است یعنی آنهایی که دارای 30 قانون فازی برای LOCA های لنگه داغ و لنگه سرد، و 5 قانون فازی برای SGTRها بودند. این جدول نشان می دهد که خطاهای

RMS برای داده های تست تقریبا برای LOCA های لنگه داغ و لنگه سرد و SGTR به ترتیب برابر ۱.۸۳٪ و ۴.۹۸٪ و ۱۸.۶۶٪ بوده است. در مواردی که در آن اندازه شکست LOCA ها باشد به فرض با خطای تصادفی کمتر از ۵ درصد پیشگویی شده است ، خطاهای RMS برای داده های تست تقریبا ۱.۷۸٪ و ۴.۹۶٪ و ۱۹.۰۱٪ برای LOCA های لنگه داغ و لنگه سرد و SGTR به ترتیب بوده است. وانگهی، در مواردی که در آن اندازه شکست LOCA باشد به فرض یک خطای پیشگویی ۵ درصدی دارد، خطاهای RMS برای داده های تست تقریبا برای LOCA های لنگه داغ و لنگه سرد و SGTR به ترتیب برابر ۲.۵۳٪ و ۵.۲۶٪ و ۱۹.۴۹٪ بوده است. از اینرو، مدلهای FNN نشان داده شده است که توانایی پیشگویی صحیح غلظت هیدروژن را تحت شرایط حادثه شدید دارد.

5-نتیجه گیری

داخل درون داره راکتور، لازم است که از افزایش غلظت هیدروژن بیش از ۴ درصد برای پیشگیری از انفجار هیدروژن جلوگیری گردد. این مقاله یک مدل FNN را مطرح می سازد که برای پیشگویی غلظت هیدروژن در درون داره تحت شرایط حادثه شدید تدوین گردیده است. به عنوان ورودی اش، این مدل از متغیرها برای زمانی که بعد از بسته شدن راکتور سپری شده است و اندازه شکست پیشگویی شده LOCA استفاده می کند. مدل FNN تدوین گردید و با استفاده از داده های شبیه سازی کد MAAP4 برای OPR1000 تایید گردید. مدل FNN تدوین شده قادر به پیشگویی غلظت هیدروژن در درون داره در زمانی خاص با استفاده از اندازه شکست LOCA پیشگویی شده و روند در حال تغییر در غلظت هیدروژن در درون داره بعد از یک LOCA می باشد. خطاهای RMS مدل FNN تقریبا برابر با ۱.۸۳٪ و ۴.۹۸٪ و ۱۸.۶۶٪ به ترتیب برای LOCA های لنگه داغ و لنگه سرد و SGTR می باشد. نتایج پیشگویی نشان می دهد که مدل FNN قادر به پیشگویی صحیح غلظت هیدروژن برای LOCA های لنگه داغ و لنگه سرد می باشد. مدل FNN تدوین شده بنا به انتظار برای فراهم کردن اطلاعات کارامد برای اپراتورها در موقعیت های حادثه شدید مفید می باشد.

REF ERENC ES

- [1] J.W. Hines, D.J. Wrest, R.E. Uhrig, Signal validation using an adaptive neural fuzzy inference system, *Nucl. Technol.* 119 (1997) 181–193.
- [2] M.G. Na, A neuro-fuzzy inference system for sensor failure detection using wavelet denoising, PCA and SPRT, *Journal of the Korean Nucl. Soc.* 33 (2001) 483–497.
- [3] J. Garvey, D. Garvey, R. Seibert, J.W. Hines, Validation of online monitoring techniques to nuclear plant data, *Nucl. Eng. Technol.* 39 (2007) 149–158.
- [4] E.B. Bartlett, R.E. Uhrig, Nuclear power plant diagnostics using an artificial neural network, *Nucl. Technol.* 97 (1992) 272–281.
- [5] M. Marseguerra, E. Zio, Fault diagnosis via neural networks: The Boltzmann machine, *Nucl. Sci. Technol.* 117 (1994) 194–200.
- [6] Y.G. No, J.H. Kim, M.G. Na, D.H. Lim, K.I. Ahn, Monitoring severe accidents using AI techniques, *Nucl. Eng. Technol.* 44 (2012) 393–404.
- [7] A. Gofuku, H. Yoshikawa, S. Hayashi, K. Shimizu, J. Wakabayashi, Diagnostic techniques of a small-break loss-of-coolant accident at a pressurized water reactor plant, *Nucl. Technol.* 81 (1988) 313–332.
- [8] M.G. Na, S.M. Lee, S.H. Shin, D.W. Jung, S.P. Kim, J.H. Jeong, B.C. Lee, Prediction of major transient scenarios for severe accidents of nuclear power plants, *IEEE Trans. Nucl. Sci.* 51 (2004) 313–321.
- [9] S.W. Cheon, S.H. Chang, Application of neural networks to a connectionist expert system for transient identification in nuclear power plants, *Nucl. Technol.* 102 (1993) 177–191.
- [10] Y. Bartal, J. Lin, R.E. Uhrig, Nuclear power plant transient diagnostics using artificial neural networks that allow don't know classifications, *Nucl. Technol.* 110 (1995) 436–449.
- [11] S.H. Park, J.H. Kim, K.H. Yoo, M.G. Na, Smart sensing of the RPV water level in NPP severe accidents using a GMDH algorithm, *IEEE Trans. Nucl. Sci.* 61 (2014) 931–938.
- [12] S.H. Park, D.S. Kim, J.H. Kim, M.G. Na, Prediction of the reactor vessel water level using fuzzy neural networks in severe accident circumstances of NPPs, *Nucl. Eng. Technol.* 46 (2014) 373–380.
- [13] M.G. Na, H.Y. Yang, D.H. Lim, A soft-sensing model for feedwater flow rate using fuzzy support vector regression, *Nucl. Eng. Technol.* 40 (2008) 69–76.
- [14] J.S. Rogerjang, C.T. Sun, Functional equivalence between radial basis function networks and fuzzy inference systems, *IEEE Trans. Neural Networks* 4 (1993) 156–159.
- [15] MAAP4 - Modular Accident Analysis Program for LWR Power Plants User's Manual, prepared by Fauske & Associates, LLC for EPRI, Project RP3131-02, May 1994 – June 2005
- [16] T. Takagi, M. Sugeno, Fuzzy identification of systems and its applications to modeling and control, *IEEE Trans. Syst. Man. Cybern. SMC-15* (1985) 116–132.
- [17] E.H. Mamdani, S. Assilian, An experiment in linguistic synthesis with a fuzzy logic controller, *Int. J. Man Mach. Stud.* 7 (1975) 1–13.
- [18] S.H. Lee, Y.G. No, M.G. Na, K.I. Ahn, S.Y. Park, Diagnostics of loss of coolant accidents using SVC and GMDH models, *IEEE Trans. Nucl. Sci.* 58 (2011) 267–276.
- [19] M.G. Na, W.S. Park, D.H. Lim, Detection and diagnostics of loss of coolant accidents using support vector machines, *IEEE Trans. Nucl. Sci.* 55 (2008) 628–636.
- [20] M.G. Na, S.H. Shin, D.W. Jung, S.P. Kim, J.H. Jeong, B.C. Lee, Estimation of break location and size for loss of coolant accidents using neural networks, *Nucl. Eng. Design* 232 (2004) 289–300.



برای خرید فرمت ورد این ترجمه، بدون واتر مارک، اینجا کلیک نمایید.



این مقاله، از سری مقالات ترجمه شده رایگان سایت ترجمه فا میباشد که با فرمت PDF در اختیار شما عزیزان قرار گرفته است. در صورت تمایل میتوانید با کلیک بر روی دکمه های زیر از سایر مقالات نیز استفاده نمایید:

✓ لیست مقالات ترجمه شده

✓ لیست مقالات ترجمه شده رایگان

✓ لیست جدیدترین مقالات انگلیسی ISI

سایت ترجمه فا؛ مرجع جدیدترین مقالات ترجمه شده از نشریات معتبر خارجی