

تخمین فشار متوسط دینامیکی در جریان‌های دوفازی آب و هوا با استفاده از شبکه‌های عصبی مصنوعی و سیستم عصبی - فازی تطبیقی

فائزه مقدس^۱، عبدالرضا کبیری سامانی*^۲ و مریم ذکری^۳

^۱ دانشجوی کارشناسی ارشد مهندسی آب، دانشکده مهندسی عمران، دانشگاه صنعتی اصفهان

^۲ دانشیار، دانشکده مهندسی عمران، دانشگاه صنعتی اصفهان

^۳ دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان

(دریافت: ۹۵/۱۱/۷، پذیرش: ۹۶/۶/۴، نشر آنلاین: ۹۶/۶/۵)

چکیده

جریان دوفازی در سازه‌های گوناگون از جمله سیستم‌های انتقال آب و خطوط لوله دریایی انتقال نفت و در سازه‌های هیدرولیکی از جمله سرریزهای نیلوفری، شفت‌های قائم، کالورت‌ها و تونل‌ها و مجاری بسته اتفاق می‌افتد. پیش‌بینی فشار دینامیکی در جریان‌های دوفازی جهت طراحی بهینه و مناسب و جلوگیری از وقوع مشکلات ناخواسته در اثر ایجاد جریان‌های دوفازی امری ضروری است. در این تحقیق مدل‌هایی جامع جهت پیش‌بینی فشار دینامیکی در جریان‌های دوفازی آب و هوا با استفاده از شبکه‌های عصبی و سیستم عصبی - فازی تطبیقی (انفیس) ارائه می‌شود. از آنجایی که مدل انفیس در مواجهه با فرآیندهای پیچیده با تعداد پارامترهای زیاد، قوانین زیادی تولید می‌کند و حجم محاسبات را بیش‌تر می‌کند، استفاده از پیش‌پردازش خوشه‌بندی فازی کارآیی مدل انفیس را بیش‌تر و حجم محاسبات را کمتر می‌کند. استفاده از الگوریتم بهینه‌سازی ازدحام ذرات یکی دیگر از تکنیک‌های بهبود نتایج در این تحقیق است. در این پژوهش برای تنظیم وزن‌ها و بایاس‌های شبکه‌های عصبی از الگوریتم ازدحام ذرات استفاده شده است. در مدل‌های انفیس نیز در رابطه با تنظیم پارامترها، الگوریتم ترکیبی ازدحام ذرات و حداقل مربعات استفاده شده است. در این بررسی مشخص شد که نتایج حاصل از مدل‌های انفیس همراه با پیش‌پردازش خوشه‌بندی فازی و الگوریتم بهینه‌سازی ازدحام ذرات دارای دقت بالاتری هستند.

کلیدواژه‌ها: فشار متوسط، جریان دوفازی، عصبی - فازی، ازدحام ذرات.

۱- مقدمه

Mishima و Hibiki (۱۹۹۶)، به بررسی برخی از مشخصات جریان‌های دوفازی آب و هوا پرداختند. آن‌ها بر این باور بودند که پارامترهای جریان دوفازی از قبیل الگوی جریان، کسر فضای خالی، افزایش سرعت حباب‌ها و افت فشار به شدت به قطر مجرا وابسته هستند.

کبیری سامانی و همکاران در سال ۲۰۰۷ به بررسی آزمایشگاهی نوسانات فشار در جریان‌های دوفازی پرداختند. آن‌ها با تجزیه و تحلیل نتایج آزمایشگاهی در شیب‌های صفر تا ۴ درصد که متداول‌ترین شیب‌های مورد استفاده در تونل‌های آب‌بر هستند، به این نتیجه رسیدند که جریان ناپایدار آب و هوا در صورت وقوع، فشارهای دینامیکی شدیدی بر سازه اعمال می‌کند، به نحوی که گاه متوسط فشار دینامیکی اعمالی به سازه حدود ۴ و حداکثر آن به ۱۰ برابر هد استاتیکی می‌رسد. آن‌ها با توجه

گاهی در برخی از پروژه‌های مهندسی نظیر سازه‌های هیدرولیکی، جریان آب مقادیر قابل ملاحظه‌ای از هوا را با خود به سیستم وارد می‌کند و سبب تشکیل جریان دوفازی آب و هوا می‌شود. ورود هوا به مجرا می‌تواند نتیجه شکل‌گیری گردابه‌ها در ورودی مجرا باشد. ضمن وقوع پدیده جریان دوفازی در مجاری تحت فشار، نوسانات شدید و خسارت بار فشار در مجرا بروز نموده که وقوع این حالت علاوه بر اثرات و خسارات آبی در درازمدت باعث خستگی و گسیختگی سازه‌های حاوی جریان و گاه خسارت غیر قابل جبران و صرف هزینه‌های گزاف جهت اصلاح و یا بهبود عملکرد سیستم می‌شود. لذا یکی از مهم‌ترین اطلاعات لازم برای طراحی درست یک سیستم، مقدار دقیق فشار اعمالی بر مجرای حاوی جریان دوفازی است.

Rosa و همکاران (۲۰۱۰)، در تحقیقی عملکرد شبکه‌های عصبی و سیستم‌های خبره را در شناسایی الگوهای جریان در لوله‌های عمودی جریان دوفازی رو به بالا با یکدیگر مقایسه کردند.

Sebakhi (۲۰۱۰)، با استفاده از سیستم عصبی فازی تطبیقی به پیش‌بینی الگوهای جریان و افت فشار در جریان دوفازه آب و روغن پرداخت. آن‌ها دریافتند که نتایج انفیس انعطاف‌پذیرتر و قابل اعتمادتر است.

Yan و Fan (۲۰۱۴)، با استفاده از شبکه‌های عصبی مصنوعی نرخ جریان مایع و گاز در یک جریان دوفازی لخته‌ای آب و هوا را پیش‌بینی کردند. هدف از انجام تحقیق حاضر ارائه مدل‌هایی جامع جهت پیش‌بینی فشار دینامیکی در جریان‌های دوفازی آب و هوا در مجاری با قطر بالا با استفاده از سیستم‌های عصبی، عصبی-فازی تطبیقی (انفیس) و الگوریتم‌های بهینه‌سازی است.

۲- متدولوژی و مبانی مدل‌سازی

مراحل مدل‌سازی در شکل (۱) ارائه شده است. در ادامه توضیحات مربوط به قسمت‌های مختلف مدل‌سازی ارائه می‌شود.

۲-۱- مدل شبکه‌های عصبی

شبکه‌های عصبی نوعی مدل ساده‌انگارانه از سیستم‌های عصبی موجودات زنده هستند. یکی از ساده‌ترین و در عین حال کارآمدترین روش‌ها در مدل‌سازی عصب‌های واقعی، مدل پرسپترون چند لایه است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. هر لایه ممکن است از نرون‌های مختلفی تشکیل شده باشد که این موضوع به نوع کار آن‌ها بستگی دارد. اگر بردار ورودی با p ، ماتریس وزن‌ها با w و بردار بایاس‌ها با b نمایش داده شود، خروجی هر نرون با a نمایش داده می‌شود و از رابطه (۱) به دست می‌آید.

$$a = f(wp + b) \quad (1)$$

در رابطه (۱)، f به تابع محرک موسوم است. در این رابطه ماتریس w در بردار ورودی p ضرب می‌شود و سپس حاصل آن که خود یک بردار است، با بردار بایاس‌ها جمع می‌شود. توانایی و قابلیت مدل شبکه عصبی، توانایی یافتن وزن‌ها و بایاس‌ها است. بر این اساس مدل و یا به عبارت بهتر هر نرون باید آموزش ببیند. برای آموزش شبکه‌های چند لایه از الگوریتم پس انتشار خطا استفاده می‌شود. در این الگوریتم خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن مجدداً ورودی، مسیر پیش روی خود تا خروجی را تکرار می‌کند.

به پارامترهای مؤثر بر فشار دینامیکی در جریان‌های دوفازی آب و هوا رابطه‌ای برای تخمین فشار متوسط دینامیکی ارائه کردند. در تحقیق دیگری کبیری سامانی و برقی (۱۳۸۴)، به بررسی افت فشار در جریان‌های دوفازی لخته‌ای افقی پرداختند. آن‌ها برای محاسبه افت فشار از ضریب اصطکاک تجربی جریان ترکیبی آب و هوا و از رابطه داری-ویسیاخ استفاده کردند.

Zhang و همکاران (۲۰۱۰)، به بررسی افت فشار در کانال‌های کوچک پرداختند. آزمایشات آن‌ها بر روی کانال‌های مستطیلی و دایروی کوچک با قطرهای کم انجام شده است. ایشان با تحقیقات خود نشان دادند که علاوه بر پارامترهای معمول (قطر هیدرولیکی، سرعت جرمی و سایر)، عدد بدون بعد لاپلاس نیز در تغییرات افت فشار تأثیرگذار است.

Xu و همکاران (۲۰۱۲)، ۲۹ معادله و ۳۴۸۰ داده تجربی که تنها ۱۳/۷ درصد از آن‌ها مربوط به جریان آب-هوا بود، را به منظور تعیین افت فشار اصطکاک در لوله‌ها از مقالات مختلف جمع‌آوری کردند و به بررسی جامع این معادلات پرداختند.

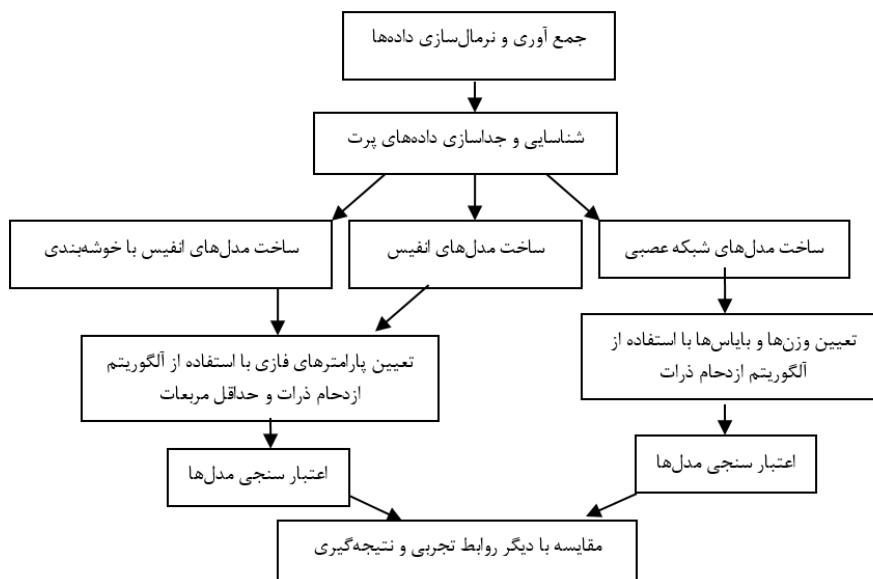
Frang و Xu (۲۰۱۳)، رابطه‌ای برای تخمین افت فشار جریان‌های دوفازی متراکم در لوله‌ها ارائه کردند.

Yan و همکاران (۲۰۱۴)، به بررسی افت فشار و ویژگی موج‌های لخته‌ای در یک جریان دوفازی پرداختند. نتایج آزمایشگاهی نشان داد که طول موج لخته‌ای و سرعت آن‌ها در جریان آرام با افزایش زاویه، افزایش می‌یابد، در حالی که در جریان آشفته این مقادیر تغییر نمی‌کنند.

همان‌طور که اشاره شد، سیستم‌های جریان دوفازی در مقایسه با جریان‌های تک‌فازی به شدت پیچیده و حاوی متغیرهای زیادی هستند که تحلیل آن‌ها دشوار بوده و نیازمند به‌کارگیری فرضیات و ابتکارات خاصی است.

علاوه بر این معادلات ارائه شده بر اساس روش‌های تجربی معمولاً دارای خطای زیادی هستند و به نظر می‌رسد، استفاده از روش‌های محاسبات نرم نظیر سیستم عصبی، منطق فازی و سیستم عصبی-فازی تطبیقی جایگزین مناسبی برای تخمین واقعی‌تری از مشخصه‌های جریان دوفازی نظیر مقادیر فشار دینامیکی در مجاری حاوی جریان دوفازی باشد. در ادامه به معرفی برخی از تحقیقات انجام شده با استفاده از این مدل‌ها در زمینه‌های مختلف اشاره می‌شود.

Shi (۲۰۰۷)، به شناسایی الگوهای جریان با استفاده از منطق فازی پرداخت. او با استفاده از روش عصبی-فازی تطبیقی الگوهای جریان مختلف را در جریان‌های دوفازی شناسایی کرد و دقت نتایج به دست آمده از این روش را نسبت به روش‌های دیگر بالاتر ارزیابی کرد.



شکل ۱- مراحل مدل سازی برای پیش بینی تغییرات فشار دینامیکی در مجرای حاوی جریان دوفازی

می شوند. لایه اول که به لایه ورودی موسوم است، عملیات فازی-سازی را انجام می دهد. در این لایه مقادیر قطعی مورد نظر وارد مدل می شوند و بر اساس تابع عضویت به صورت فازی درمی آیند. در واقع میزان تعلق هر ورودی به مجموعه فازی تعیین می شود. بنابراین خروجی لایه اول به صورت رابطه (۵) است.

$$O_i^1 = \mu_{Ai}(x) \quad (5)$$

لایه دوم شامل گره های قوانین است. در این لایه عمل گر "و" بر داده های فازی شده اعمال می گردد تا درجه فعالیت هر قانون محاسبه شود. خروجی این مرحله به صورت رابطه (۶) است.

$$O_i^2 = w_i = \mu_{Ai}(x) \times \mu_{Bi}(y) \quad (6)$$

در لایه سوم عملیات نرمال سازی خروجی های لایه دوم انجام می شود. هدف اصلی تعیین نسبت فعالیت قانون i ام نسبت به مجموع قانون ها است.

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_i w_i} \quad i = 1, 2 \quad (7)$$

در لایه چهارم که شامل گره های نتیجه است، عملیات غیرفازی سازی انجام می شود. خروجی این لایه را می توان به صورت رابطه (۸) نشان داد:

$$i = 1, 2 \quad O_i^4 = \bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i \cdot x + q_i \cdot y + r_i) \quad (8)$$

شکل کلی معادله انجام محاسبات پیش خور در مدل های شبکه عصبی به صورت رابطه (۲) است.

$$a^{m+1} = f^{m+1}(w^{m+1} \cdot a^m + b^{m+1}) \quad m = 0, 1, \dots, M-1 \quad (2)$$

در این رابطه M تعداد لایه های شبکه است. بنابراین ورودی اولیه به سیستم a^0 و خروجی نهایی از آن a^M است. الگوریتم پستانتشار خطا برای تنظیم پارامترهای موجود در شبکه اعم از وزن ها و بایاس ها، از الگوریتم حداقل میانگین مربعات خطا^۲ استفاده می کند. الگوریتم گرادین کاهشی برای وزن ها و بایاس ها هم به صورت زیر است:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \cdot \frac{\partial \hat{F}}{\partial w_{i,j}^m(k)} \quad (3)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \times \frac{\partial \hat{F}}{\partial b_i^m(k)} \quad (4)$$

در این روابط α ، نرخ یادگیری^۳ است.

۲-۲- سیستم استنتاج فازی بر پایه شبکه عصبی

Jang (۱۹۹۷)، با ارائه سیستم استنتاج فازی بر پایه شبکه عصبی تطبیقی با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با توانایی عددی یک شبکه عصبی، نشان داد که انفیس در مدل سازی فرآیندهای غیرخطی بسیار قدرتمند است. مدل های عصبی-فازی تطبیقی از پنج لایه به شرح زیر تشکیل

$$v_{ij}(t+1) = w.v_{ij}(t) + c_1.rand1_{ij} \cdot (p_{best,ij}(t) - x_{ij}(t)) + c_2.rand2_{ij} \cdot (g_{best,j}(t) - x_{ij}(t)) \quad (11)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (12)$$

x_{ij} : j زامین بعد از بردار موقعیت ذره i ام،

v_{ij} : j زامین بعد از بردار سرعت ذره i ام،

$p_{best,ij}$: j زامین بعد از بهترین موقعیت ذره i ام تا لحظه t ،

$g_{best,j}$: j زامین بعد از بهترین موقعیت که تاکنون توسط همه ذرات به دست آمده است.

w : اینرسی،

$and1_{ij}$ و $rand2_{ij}$: دو عدد تصادفی در بازه [۰ و ۱]،

$c1$ و $c2$: ضرایب شتاب هستند و نشان می‌دهند که ذره با چه شتابی به سمت p_{best} و g_{best} حرکت می‌کند.

t : زمان یا تکرار است.

۳- متغیرهای مورد بررسی، داده‌ها و مشخصات مدل‌ها

۳-۱- تحلیل ابعادی و پارامترهای مؤثر

متغیرهای مؤثر بر فشار متوسط دینامیکی در جریان دو فاز آب و هوا عبارتند از؛ مشخصات فیزیکی جریان (جرم مخصوص ρ ، لزجت دینامیکی μ و کشش سطحی σ ، مشخصات هیدرولیکی جریان (دبی فاز گاز و فاز مایع Q ، مساحت اشغال شده توسط فاز گاز و مایع A ، سرعت‌های ظاهری فازها و سرعت جریان دوفازی V ، مشخصات هندسی لوله (قطر لوله D ، فاصله بین پیژومترهای اندازه‌گیری فشار L ، شیب کف کانال S_0 و شتاب ثقل g ، بنا بر آنچه ذکر شد، کبیری سامانی و همکاران رابطه (۱۳) را برای ارتباط پارامترهای مؤثر بر فشار دینامیکی ارائه کردند:

$$\frac{hd}{h} = f(Fr, E_0, Sh, K_f, \alpha, \bar{C}, wfs) \quad (13)$$

hd/h عدد بدون بعد فشار دینامیکی که برای بی‌بعد کردن آن مقایر فشار دینامیکی بر حسب ارتفاع ستون آب ($hd=Pa/\gamma$) به ارتفاع آب در مخزن بالادست (h) تقسیم شده است. Fr ، E_0 ، Sh و We به ترتیب اعداد بی‌بعد فرود^۵ مربوط به موج لخته‌ای، ایتوس^۶، اشتروهال^۷ و وبر^۸ بوده و به صورت زیر تعریف شده‌اند:

$$Fr = \frac{c}{\sqrt{Lg}} \quad (14)$$

لایه پنجم به عنوان مرحله پایانی است و خروجی‌های نهایی از آن خارج می‌شود. خروجی این لایه به صورت رابطه (۹) است:

$$O_i^5 = f(x, y) = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad i = 1, 2 \quad (9)$$

همان‌طور که قبلاً نیز بدان اشاره شد، مدل‌های عصبی-فازی تطبیقی نیز همانند مدل‌های عصبی باید آموزش ببینند و زمانی عمل شبیه‌سازی به درستی انجام گرفته است که پارامترهای قسمت مقدم و تالی قوانین فازی به درستی تعیین شده باشند تا مقدار خطای مدل به مقدار مورد نظر برسد. در تحقیق حاضر از روش خوشه‌بندی کاهشی^۴ برای خوشه‌بندی فازی داده‌ها استفاده شده است. در این روش هر داده این پتانسیل را دارد که مرکز خوشه شود و این احتمال را بر مبنای تراکم داده‌های مجاور، محاسبه می‌کند.

۳-۲- الگوریتم ازدحام ذرات PSO

این الگوریتم اولین بار در سال ۱۹۹۵ توسط Kennedy و Eberhart ابداع و نتایج آن بیان گردید. الگوریتم ازدحام ذرات یک الگوریتم تکاملی است که با جواب‌های تصادفی شروع شده و در بین جواب‌های تولیدی، جستجو را ارائه می‌دهد. هر جواب بالقوه، ذره نامیده می‌شود. ذرات در جواب مسأله با یک سرعت پویا که برگرفته از تجربه خود ذرات و تجربه هم‌قطارهاست حرکت می‌کنند. در این روش جواب‌ها در فضای جستجو باقی می‌مانند تا اطلاعات آن‌ها به اشتراک گذاشته شود و جستجو را به سمت بهترین موقعیت در فضای جواب هدایت کنند. هر ذره در یک فضای n بعدی قرار می‌گیرد. مکان i امین ذره به صورت $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ بهترین مکانی که تا آخرین لحظه توسط i امین ذره پیدا شده (p_{best}) به صورت $P_i = (P_{i1}, P_{i2}, \dots, P_{in})$ و بهترین مکانی که توسط همه ذرات پیدا شده با نماد "gbest" نشان داده می‌شود. بردار حرکتی (v) برای ذره i ام به صورت $v_i = (v_{i1}, v_{i2}, \dots, v_{in})$ نشان داده می‌شود. برای جلوگیری از واگرایی الگوریتم سرعت‌ها و مکان ذرات محدود می‌شوند $v_{ij} \in [v_{min}, v_{max}]$ و $x_{ij} \in [x_{min}, x_{max}]$ تعداد ذرات گروه برای همگرایی بهتر معمولاً با سعی و خطا انتخاب می‌شود. شرط توقف این است که بیشترین تغییر در مقدار بهترین جواب برای تعداد معینی از اجرای الگوریتم کمتر از خطای مشخص باشد:

$$|f(\hat{y}(t)) - f(\hat{y}(t-k))| < e \quad (k = 1, 2, \dots, i) \quad (10)$$

ذرات توسط روابط زیر مکان خود را تغییر می‌دهند:

معیاری از فاصله هر یک از مشاهدات در فضای چند بعدی از مرکز میانگین تمام مشاهدات است. در هر مدل از میان داده‌های موجود به صورت تصادفی ۷۰ درصد برای آموزش سیستم، ۲۰ درصد برای آزمون سیستم و مابقی برای سنجش دقت انتخاب شدند. در جدول (۱)، برخی اطلاعات مربوط به ورودی‌ها و خروجی‌های بی‌بعد مورد استفاده در مدل‌های مذکور آورده شده است.

جدول ۱- اطلاعات مربوط به ورودی‌ها و خروجی مدل‌های داده محور مورد استفاده

نام متغیر	بازه تغییرات	میانگین	انحراف معیار
Fr	[۰/۱۷۴۹ و ۰/۶۰۳۱]	۰/۳۷۰۸	۰/۰۶۴۲
E _o	[۴۵/۴۶۳۵ و ۱۰۴۶/۷۰۱]	۸۱۲/۷۵۸۶	۲۱۵/۶۰۸۴
Sh	[۰/۰۰۰۳ و ۰/۰۱۱۳]	۰/۰۰۴۷۸	۰/۰۰۲۱
K _f	[۱۵/۶۰۵۱ و ۳۹۵/۷۵۶۹]	۱۰۹/۹۳۳۵	۸۰/۲۷۹۰
α	[۰/۰۲۹۷ و ۱/۳۴۳۷]	۰/۲۴۸۵	۰/۲۰۸۰
C̄	[۰/۰۸۹۱ و ۰/۶۳۵۹]	۰/۲۸۳۲	۰/۱۲۲۶
wfs	[۱۸۷/۰۲۹۷ و ۲۷۴۵/۴۴۹]	۹۲۰/۹۷۰۵	۵۶۰/۹۳۹۸
hd/h	[۱/۳۶ و ۳/۷۹۱]	۲/۵۳۱۳	۰/۵۴۶۱

$$X_n = (X - X_{min}) / (X_{max} - X_{min}) \quad (23)$$

x داده‌های اصلی، X_{max} و X_{min} مقدار حداقل و حداکثر داده‌ها و X_n داده‌های نرمالایز شده هستند. همان‌طور که در جدول ملاحظه می‌شود بازه تغییرات متغیرها، متفاوت است. جهت آموزش بهینه انجیس کلیه مقایر فوق توسط رابطه (۲۳) نرمالایز شده و در محدوده صفر تا یک قرار گرفته است. داده‌های نرمالایز شده بعد از مدل‌سازی به داده‌های اصلی بازگردانده می‌شود.

۳-۳- مشخصات مدل شبکه عصبی

برای ایجاد مدل شبکه عصبی، از جعبه ابزار Neural Networks نرم‌افزار MATLAB 8.0.1.604 استفاده شده است. در مجموع تعداد ۱۰ مدل شبکه عصبی با در نظر گرفتن $K=5$ از روش K Fold Cross Validation برای تعیین فشار متوسط دینامیکی ایجاد شد. این مدل‌ها با تعداد لایه‌ها و نرون‌های مختلف آموزش داده شد و نتایج با استفاده از روش میانگین مربعات خطا مورد بررسی قرار گرفت. بهترین تعداد لایه‌ها و نرون‌ها به ترتیب ۳ و ۱۰، به دست آمد. در شبکه‌های عصبی به دلیل این که وزن‌های اولیه ورودی به شبکه توسط سیستم حدس زده می‌شود، در هر بار اجرای شبکه با تعداد لایه‌ها و نرون‌های مساوی، نتایج متفاوتی حاصل می‌شود. به این جهت برای هر مدل، میانگین نتایج حاصل از پنج بار اجرای شبکه عصبی به عنوان پیش‌بینی سیستم در نظر گرفته می‌شود. برای

$$E_0 = \frac{gD\bar{\rho}}{\sigma_w} \quad (15)$$

$$Sh = \frac{\bar{\rho}Df}{G} \quad (16)$$

$$We = \frac{G^2 D}{\sigma \bar{\rho}} \quad (17)$$

$$wfs = \frac{We}{Fr \sqrt{1 - S_0}} \quad (18)$$

که c, α, L, D و f به ترتیب سرعت موج لخته‌ای، طول موج لخته‌ای، کسر فضای خالی (نسبت حجم گاز در یک طول موج لخته‌ای به حجم کل در طول موج مورد نظر)، قطر هیدرولیکی، فرکانس موج و چگالی دوفازی هستند. ضمناً چگالی دو فازی به صورت زیر بیان می‌شود:

$$\bar{\rho} = \alpha \rho_a + (1 - \alpha) \rho_w \quad (19)$$

G سرعت جرمی جریان است و از تقسیم دبی جرمی جریان بر سطح جریان به دست می‌آید.

$$G = \frac{W}{A} \quad (20)$$

همچنین در رابطه آنالیز ابعادی K_f و \bar{C} به ترتیب ضریب افت اصطکاک و غلظت متوسط هستند:

$$K_f = f_{tp} \frac{L}{D} \quad (21)$$

$$\bar{C} = \frac{\beta}{\beta + 1} \quad (22)$$

در رابطه (۲۱)، f_{tp} ضریب اصطکاک دوفازی است که با استفاده از رابطه بلازیوس محاسبه می‌شود.

۳-۲- مشخصات داده‌ها

در این تحقیق از نتایج مدل‌سازی آزمایشگاهی کبیری سامانی و همکاران شامل مجرای با مقطع دایره و با قطر داخلی ۹ سانتی‌متر و طول ۱۰ متر با جداره شفاف برای پیش‌بینی تغییرات فشار متوسط دینامیکی در جریان دو فازی آب و هوا استفاده شده است. در طول لوله در مقاطع مختلف با فاصله ۱/۲ متر حدود ۳۰۰ پیزومتر برای اندازه‌گیری فشار و نوسانات آن مورد استفاده قرار گرفته است. تعداد داده‌های موجود برای مدل‌سازی فشار دینامیکی برابر با ۳۰۲ عدد است که ۱۵ عدد از آن‌ها با استفاده از روش ماهالانوبیس، به عنوان داده پرت شناخته شده و حذف شدند. فاصله ماهالانوبیس که معیار T^2 نیز نام دارد،

در این تحقیق برای تعیین دقیق شعاع خوشه‌ها از الگوریتم ازدحام ذرات استفاده شده است. سپس سیستم با توجه به شعاع مشخص شده از روش خوشه‌بندی کاهشی، داده‌ها را دسته‌بندی می‌کند. پس از این پیش‌پردازش، هر دسته از داده‌ها به عنوان یک ورودی مستقل وارد مدل انفیس می‌شود و با ۷ تابع عضویت که برابر تعداد داده‌های ورودی است، یک قانون را تشکیل می‌دهد. بنابراین تنها به تعداد دسته‌های ورودی قانون تشکیل می‌شود.

۳-۶- بهینه‌سازی مدل‌های عصبی - فازی تطبیقی

در یک مدل انفیس دو دسته پارامتر وجود دارد. دسته اول مربوط به بخش مقدم قوانین فازی و دسته دوم پارامترهای مربوط به قسمت تالی قوانین فازی است. نوع تابع عضویت متغیرهای ورودی همه مدل‌ها از نوع زنگوله‌ای و نوع تابع عضویت متغیرهای خروجی خطی است. یک قانون فازی در این مدل به صورت $\text{if } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } A_2 \text{ and } x_7 \text{ is } A_7 \text{ then } f_i = p_i$ است. با توجه به این که هر ورودی دارای دو تابع عضویت و هر تابع عضویت دارای ۳ متغیر است، بنابراین تعداد متغیرها در قسمت مقدم قوانین ۴۲ عدد است که از طریق الگوریتم ازدحام ذرات به دست می‌آید. قبل از استفاده از الگوریتم ازدحام ذرات باید پارامترهای آن مشخص شود. همان‌طور که پیش‌تر نیز اشاره شد، این پارامترها شامل ضریب اینرسی w و ضریب خود ادراکی ذره c_1 ، ضریب ادراک جمعی c_2 و تعداد جمعیت و تکرار است. تعداد تکرار با اجرای الگوریتم و مشاهده میزان همگرایی به نوعی معیار پایان اجرای الگوریتم است. در مطالعه حاضر مقادیر توصیه شده مطالعات گذشته بررسی و متناسب با نتایج، پارامترهای همگرایی روش انتخاب شده است. ضریب اینرسی برابر با $W_{\text{iter}} = 0.99W_{\text{iter}}$ و c_1 ، پارامترهای اینرسی c_1 و c_2 برابر با ۲، تعداد ذرات ۳۰-۸۰ و تعداد تکرار در الگوریتم ۱۰۰-۴۰۰ است. کد نوشته شده در نرم‌افزار Matlab ورودی‌ها را از پرونده Excel دریافت و در هر بار اجرای برنامه ابتدا از طریق الگوریتم ازدحام ذرات مقادیری برای پارامترهای قسمت مقدم قوانین (۴۲ پارامتر) در نظر گرفته و سپس پارامترهای قسمت تالی قوانین (۱۲۸ پارامتر) را با استفاده از روش الگوریتم حداقل مربعات تعیین می‌کند. سپس نتایج خروجی انفیس را با نتایج واقعی مقایسه کرده و اگر خطای قابل قبول حاصل نشده باشد، الگوریتم ازدحام ذرات و حداقل مربعات دوباره تکرار شده و پارامترهای قوانین فازی مجدداً به دست می‌آیند. این عمل آن قدر تکرار می‌شود، تا برنامه به میزان خطای مورد نظر برسد. تعداد تکرار مشخص شده برای اجرای برنامه شرط دیگری برای رسیدن به جواب بهینه است. برنامه مربوط به مدل انفیس همراه با پیش‌پردازش خوشه‌بندی نیز به همین

آموزش مدل از الگوریتم پس انتشار خطا استفاده شده است. توابع انتقال مورد استفاده در لایه پنهان، تانژانت سیگموئید است. در لایه خروجی نیز به طور پیش‌فرض تابع خطی مورد استفاده قرار می‌گیرد.

۳-۴- مشخصات مدل عصبی - فازی تطبیقی

برای ایجاد مدل عصبی - فازی تطبیقی، از جعبه ابزار Fuzzy Logic نرم‌افزار MATLAB استفاده شده است. در مدل‌های عصبی - فازی تطبیقی نقش داده‌هایی که برای کنترل مدل به کار می‌روند، بسیار مهم است. این شبیه‌سازی به صورت حفظ داده‌ها انجام می‌شود و چنانچه برای داده‌های آموزش ندیده مدل مورد استفاده قرار گیرد، پیش‌بینی به نحو مناسبی انجام نشده و خطای سیستم افزایش می‌یابد. این حالت به اصطلاح پدیده بیش‌برازش^۹ نامیده می‌شود. نوع تابع عضویت متغیرهای ورودی مدل‌های عصبی - فازی تطبیقی مورد استفاده زنگوله‌ای، نوع تابع عضویت متغیر خروجی ثابت و تعداد قوانین ۱۲۸ عدد است.

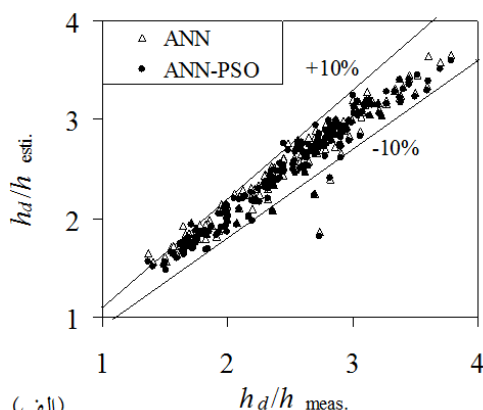
۳-۵- مشخصات مدل عصبی - فازی تطبیقی همراه با

پیش‌پردازش خوشه‌بندی فازی


در مواردی که تعداد ورودی‌ها و توابع عضویت به صورتی باشد که قوانین زیادی به وسیله انفیس تشکیل شود، تعداد پارامترهای تنظیم‌پذیر سیستم بسیار زیاد شده و این امر باعث پیچیدگی و طولانی شدن زمان آموزش سیستم می‌گردد. در انفیس به ازای تمام نگاشت‌های موجود بین توابع عضویت ورودی‌ها، قانون تشکیل می‌شود. هر چند هیچ رابطه‌ای بین آن‌ها نباشد. بنابراین باید به روشی تعداد قوانین و پارامترهای تنظیم‌پذیر کاهش داده شود. یکی از این روش‌ها با حفظ تأثیر تمامی ورودی‌ها در نتیجه نهایی، عملیات پیش‌پردازش خوشه‌بندی فازی با روش SUBCLUST است. مشخصات مدل انفیس با پیش‌پردازش SUBCLUST در جدول (۲) آورده شده است. لازم به ذکر است که متغیرهای ورودی این سیستم نیز متغیرهای نام‌برده در جدول (۱) است.

جدول ۲- مشخصات مدل‌های انفیس با پیش‌پردازش

SUBCLUST			
شماره مدل	شعاع خوشه‌ها	نوع تابع عضویت متغیر خروجی	تعداد قوانین
مدل ۱	۰/۳۶	خطی	۸
مدل ۲	۰/۳۱۳	خطی	۱۳
مدل ۳	۰/۳۶	خطی	۱۱
مدل ۴	۰/۳۴	خطی	۱۰
مدل ۵	۰/۲۱۴	خطی	۲۳



(الف)



(ب)

شکل ۲- مقایسه بین نتایج شبکه عصبی و عصبی و PSO در تخمین فشار دینامیکی مربوط به داده های: الف) آموزشی، ب) تست

نتایج به دست آمده از تابع خطای NRMSE مربوط به بهترین مدل از ۵ مدل پیش بینی فشار دینامیکی برای داده های آزمون و تست به ترتیب برابر با ۰/۱۳۴۳ و ۰/۲۲ و برای مدل بهینه شده با PSO به ترتیب ۰/۱۲ و ۰/۱۸۵۵ است. در مجموع، مقادیر خطا در مدل های ANFIS نسبت به مدل های ANN، کاهش یافته است. همان طور که اشاره شد، از پیش پردازش خوشه بندی فازی به روش SUBCLUST تنها برای مدل های عصبی- فازی تطبیقی به دلیل دارا بودن تعداد زیاد قوانین فازی استفاده شده است. شکل های (۴-الف) و (۴-ب) به ترتیب ارتباط بین مقادیر واقعی فشار دینامیکی در جریان دو فازی را برای داده های آموزش و تست در مقابل مقادیر پیش بینی شده توسط مدل- های ANN-PSO و عصبی- فازی تطبیقی در ترکیب با الگوریتم ازدحام ذرات ANFIS-PSO-SUBC نشان می دهند. پیش بینی مدل ها برای داده های مذکور مناسب بوده و مقادیر خطا نسبت به مدل های ANN و ANN-PSO کاهش یافته است. میزان خطای NRMSE این داده ها در مدل های بهینه شده ۰/۱۳۵ و ۰/۱۹ است. در کل نتایج نسبت به مدل های بدون خوشه بندی بهبود

صورت است. تفاوت آن با مدل های انفیس در نوع تابع عضویت خروجی است که در مدل انفیس ثابت و در این مدل ها خطی است.

۴- توابع خطا

برای مقایسه نتایج حاصل از مدل های مختلف در این تحقیق و همچنین مقایسه با رابطه ها سایر محققین در تحقیقات گذشته، در نظر گرفتن یک معیار مقایسه ضروری است. توابع خطای در نظر گرفته شده برای مقایسه به صورت روابط (۲۴) تا (۲۶) هستند.

$$MSE = \frac{1}{n} \sum_{i=1}^n (F(x) - f(x))^2 \quad (24)$$

$$NRMSE = \sqrt{\frac{\sum (f(x) - F(x))^2}{\sum (f(x) - \bar{f})^2}} \quad (25)$$

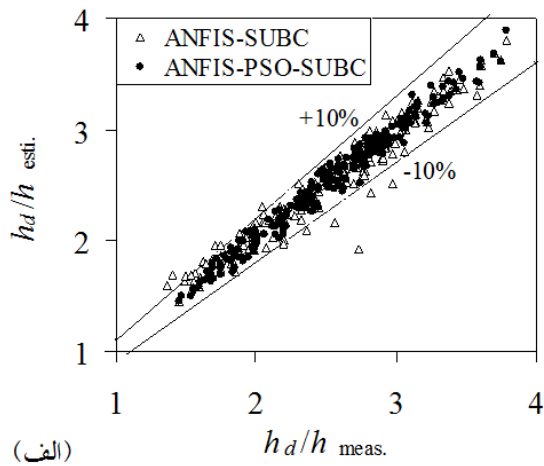
$$R^2 = 1 - \frac{\sum_{i=1}^n (f(x) - F(x))^2}{\sum_{i=1}^n (f(x) - \bar{f})^2} \quad (26)$$

در روابط اخیر $f(x)$ مقدار مشاهده شده تابع، $F(x)$ مقدار خمینی و \bar{f} متوسط مقادیر واقعی است. مقادیر توابع خطای MSE و NRMSE برای رسیدن به مقدار بهینه باید کمینه و نزدیک به صفر و تابع R^2 باید بیشینه و نزدیک به یک شود.

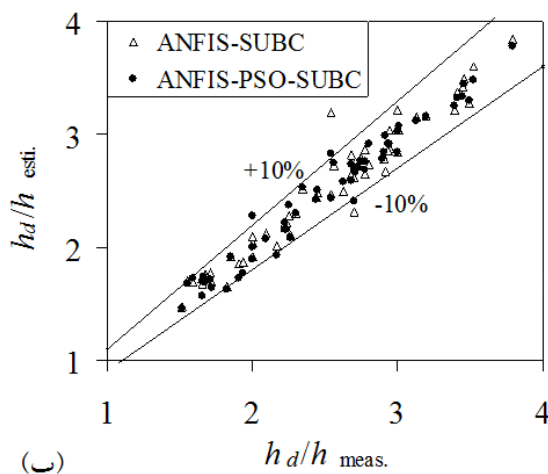
۵- نتایج مدل سازی

در این قسمت نتایج به دست آمده از مدل های شبکه عصبی ANN و مدل بهینه شده به وسیله الگوریتم ازدحام ذرات ANN PSO در پیش بینی فشار متوسط دینامیکی طبق شکل های (۲-الف) و (۲-ب) برای داده های آموزش و آزمون آورده شده است. به دلیل ازدیاد شکل ها و گستردگی مطالب، همه شکل ها برای ۵ مدل رسم نشده و تنها به رسم بهترین مدل از ۵ مدل شبکه عصبی و بهترین مدل از ۵ مدل عصبی و PSO اکتفا می شود. در میان مدل ها، مدل شماره ۱ دارای کمترین میزان خطا و بهترین مدل بوده است.

نتایج نشان می دهند که الگوریتم بهینه سازی تا حدودی نتایج شبکه عصبی را بهبود داده است. میزان خطای NRMSE این داده ها در مدل عصبی برابر با ۰/۳۵ و در مدل بهینه شده برابر ۰/۲۲ است. شکل های (۳-الف) و (۳-ب)، به منظور مقایسه نتایج خروجی مدل عصبی- فازی تطبیقی ANFIS و مدل عصبی- فازی بهینه سازی شده با الگوریتم ازدحام ذرات ANFIS-PSO ارائه شده اند.




(الف)



(ب)

شکل ۴- مقایسه نتایج مدل انفیس-نخوشه‌بندی و مدل بهینه‌شده در تخمین فشار دینامیکی مربوط به داده‌های: (الف) آموزش، (ب) تست




شکل ۵- مقایسه بین نتایج مدل بهینه‌شده انفیس و رابطه تجربی کبیری سامانی و همکاران در پیش‌بینی فشار دینامیکی


نتایج مربوط به مدل بهینه‌شده انفیس همراه با پیش‌پردازش خوشه‌بندی فازی با رابطه تجربی کبیری سامانی و همکاران در

یافته و خطا کاهش یافته است. بنابراین خوشه‌بندی فازی در بهبود نتایج بسیار مؤثر است.

نتایج مدل‌های انفیس خوشه‌بندی شده نسبت به مدل‌های بدون خوشه‌بندی در بخش پیشین بسیار بهبود یافته تا جایی که در یکی از مدل‌ها میزان خطای NRMSE تا ۱۴ درصد اختلاف دارد. مقادیر NRMSE و R^2 در مورد داده‌های آموزش و تست مدل انفیس با خوشه‌بندی فازی به ترتیب (۰/۲۳ و ۰/۹۵) و (۰/۹۲ و ۰/۲۳) است. حال آن که همین مقادیر برای مدل انفیس بهینه شده در ترکیب با خوشه‌بندی فازی به ترتیب (۰/۱۸ و ۰/۹۶) و (۰/۱۹ و ۰/۹۶) است. جدول (۳) میانگین مقادیر خطا و ضریب همبستگی به دست آمده از نتایج مدل‌های مذکور را نشان می‌دهند. بر این اساس مدل انفیس با پیش‌پردازش خوشه‌بندی و بهینه شده با الگوریتم ازدحام ذرات دارای کمترین میزان خطا است. در ادامه بهترین مدل با کمترین میزان NRMSE با روابط تجربی موجود مقایسه می‌شود.



(الف)



(ب)

شکل ۳- مقایسه نتایج مدل انفیس و مدل انفیس بهینه شده در تخمین فشار دینامیکی مربوط به داده‌های: (الف) آموزش، (ب) تست

بوده است. از آن جایی که تعداد متغیرهای ورودی به مدل برای پیش‌بینی فشار دینامیکی برابر با ۷ است، با در نظر گرفتن تعداد ۲ تابع عضویت برای هر متغیر مدل انفیس تعداد ۱۲۸ قانون فازی تولید می‌کند. در مدل انفیس به ازای تمام نگاشت‌های موجود بین توابع عضویت ورودی قانون تشکیل می‌شود، هر چند هیچ رابطه‌ای بین آن‌ها نباشد. بنابراین باید به روشی تعداد قوانین و پارامترهای تنظیم‌پذیر کاهش داده شوند. یکی از این روش‌ها با حفظ تأثیر تمامی ورودی‌ها در نتیجه نهایی، عملیات پیش‌پردازش خوشه‌بندی فازی با روش SUBCLUST است. یکی از رایج‌ترین الگوریتم‌ها جهت آموزش شبکه‌های عصبی، الگوریتم یادگیری پس‌انتشار خطا است. الگوریتم استاندارد پس-انتشار خطا، یک الگوریتم بر اساس گرادیان کاهش است. روش گرادیان کاهش در بهینه‌سازی در برخورد با اولین بهینه محلی متوقف می‌شود. بنابراین استفاده از الگوریتمی هوشمند جهت تنظیم پارامترهای شبکه عصبی و سیستم‌های عصبی-فازی که در آن‌ها نیز از روش گرادیان کاهش استفاده می‌شود، روش مناسبی است. از الگوریتم‌های پرکاربرد در این زمینه که در این تحقیق از آن استفاده شد، الگوریتم ازدحام ذرات PSO است. بهینه‌سازی مدل‌های عصبی-فازی تطبیقی به صورت روش ترکیبی از الگوریتم ازدحام ذرات و روش حداقل مربعات به بهبود نتایج کمک کرده است. در پیش‌بینی فشار متوسط دینامیکی مدل‌های شبکه عصبی، مقدار خطای تابع NRMSE نسبت به فرمول تجربی کبیری سامانی و همکاران بیشتر است. بنابراین در پیش‌بینی فشار متوسط دینامیکی مدل‌های عصبی موفق نیستند که احتمالاً مربوط به تعداد زیاد متغیرهای ورودی باشد. در مورد مدل‌های عصبی-فازی برای داده‌های آموزش یافته نتایج ۲۰٪ بهبود یافته است. استفاده از پیش‌پردازش خوشه‌بندی در پیش-بینی فشار دینامیکی میزان خطای NRMSE داده‌های آموزش یافته را نسبت به مدل‌های بدون خوشه‌بندی ۱۸٪ کمتر کرده است. همچنین بهینه‌سازی مدل‌های خوشه‌بندی شده نتایج را ۲۱٪ نسبت به مدل‌های بهینه نشده و ۱۲٪ نسبت به رابطه کبیری سامانی و همکاران بهبود بخشیده است.

۷- مراجع

باقری س، قیصری م، ایوبی ش، لوابی ن، "پیش‌بینی عملکرد ذرت علوفه‌ای با استفاده از شبکه‌های عصبی مصنوعی"، مجله پژوهش‌های تولید گیاهی، ۱۳۹۱، جلد نوزدهم، شماره چهارم، ۷۷-۹۵.

کبیری سامانی ع، برقی س، سعیدی م، "بررسی آزمایشگاهی نوسانات فشار در مقطع مجاری آب‌بر حاوی جریان ناپایار آب و هوا"، مجله استقلال، ۱۳۸۴، سال ۲۲، شماره ۲، ۶۹-۸۶.

شکل (۵) مقایسه شده است. همان‌طور که در شکل (۵) مشخص است، نتایج مدل انفیس با خوشه‌بندی کاهش فازی به همراه الگوریتم ازدحام ذرات در مقایسه با رابطه کبیری سامانی و برقی به مقادیر واقعی فشار متوسط دینامیکی بسیار نزدیک‌تر است و دارای خطای کم‌تری است. به طوری که میزان تابع خطا برای رابطه کبیری سامانی و همکاران ۰/۲۵ و برای مدل انفیس برای داده‌های آموزش نیافته (مدل ۱) ۰/۱۹ است.

جدول ۳- مقایسه بین نتایج مدل‌های شبکه عصبی و انفیس

مدل	آموزش		آزمون	
	NRMSE	R2	NRMSE	R2
ANN	۰/۲۵	۰/۹۳	۰/۳۵	۰/۸۸
ANN-PSO	۰/۲۵	۰/۹۱	۰/۳	۰/۹۱
ANFIS	۰/۲۲	۰/۹۵	۰/۲۲	۰/۹۴
ANFIS-PSO	۰/۱۸۶	۰/۹۷	۰/۱۹	۰/۹۶
ANFIS-SUBC	۰/۲۲۸	۰/۹۵	۰/۲۳	۰/۹۲
ANFIS-PSO-SUBC	۰/۱۸	۰/۹۶	۰/۱۹	۰/۹۶

۵- آنالیز حساسیت

فرآیند آنالیز حساسیت، میزان حساسیت مدل را نسبت به متغیرهای ورودی آن نشان می‌دهد. در این پژوهش برای انجام آنالیز حساسیت مدل‌ها از روش Statsoft استفاده شده است. در این روش مقادیر ضریب حساسیت متغیرهای ورودی از تقسیم خطای کل شبکه در غیاب یک متغیر بر خطای کل شبکه در حضور تمامی متغیرهای ورودی، به دست می‌آید. بر این اساس اگر مقدار ضریب حساسیت یک متغیر بیشتر از یک باشد، آن متغیر سهم زیادی در تغییرپذیری مؤلفه‌های خروجی دارد. بر اساس آنالیز حساسیت انجام شده در صورت کاربرد تمام پارامترهای بی‌بعد مؤثر، مقدار خطای MSE برابر ۰/۰۲۱ است. در صورت حذف هر یک از پارامترهای بی‌بعد E_0 ، F_r ، α ، K_f ، \bar{C} و wfs زوج (MSE و فاکتور حساسیت) به ترتیب برابر (۰/۰۲۳ و ۰/۰۹۵)، (۰/۰۲۹ و ۰/۱۳۸)، (۰/۰۳۲ و ۰/۰۵۲)، (۰/۰۳۰ و ۰/۰۴۲)، (۰/۰۲۹ و ۰/۱۳۸)، (۰/۰۲۴ و ۰/۰۱۴) و (۰/۰۲۹ و ۰/۱۳۸) خواهد شد. لذا تأثیر متغیر بی‌بعد sh از سایر متغیرهای ورودی بیشتر است. اما به طور کلی تأثیر متغیرهای ورودی به هم نزدیک است. لذا در محاسبه مقدار فشار دینامیکی باید همه این عوامل منظور شوند.

۶- جمع‌بندی و نتیجه‌گیری

هدف از تحقیق حاضر پیش‌بینی فشار دینامیکی در جریان دو فازی آب و هوا با استفاده از مدل‌های شبکه عصبی و انفیس در دو حالت استفاده یا عدم استفاده از الگوریتم‌های بهینه‌سازی

- Yan C, Yan C, Sun L, Wang Y, Zhang X, "Slug behavior and pressure drop of adiabatic slug flow in a narrow rectangular duct under inclined conditions", *Annals of Nuclear Energy*, 2014, 64, 21-31.
- Zhang W, Hibiki K, Mishima K, "Correlations of two-phase frictional pressure drop and void fraction in mini channel", *International Journal of Heat and Mass*, 2010, 53(1-3), 453-465.
- De Maesschalk R, Jouan-Rimbaud D, Massart DL, "The mahalanobis distance", *Chemometrics and Intelligent Laboratory Systems*, 2000, 50(1), 1-18.
- Eberhart RC, Kennedy J, "A new optimizer using particle swarm theory", *Sixth International Symposium on Micro Machine and Human Science*, IEEE Service Center, Piscataway, NJ, 1995, 39-43.
- Fan S, Yan T, "Two-phase air-water slug flow measurement in horizontal pipe using conductance probes and neural networks", *IEEE Transaction on Instrumentation and Measurement*, 2014, 63(2), 456-466.
- Jang JSR, Sun CT, Mizutani E, "Neuro-Fuzzy modeling and soft computing", Prentice Hall, Englewood Cliffs, 1997.
- Kabiri-Samani AR, Borghei SM, Saidi MH, "Fluctuations of air-water two-phase flow in horizontal and inclined water pipelines", *Journal of fluid Engineering. ASME*, 2007, 129(1), 1-14.
- Kabiri-Samani AR, Borghei SM, "Pressure loss in a horizontal two-phase slug flow", *Journal of Fluids Engineering*, 2010, 132(7).
- Martin CS, "Entrapped air in pipelines", *Proceedings of the 2nd International Conference on Pressure Surges*, BHRA Fluid Engineering, Cranfield, Bedford, England, 1976.
- Mishima K, Hibiki T, "Some characteristics of air-water two-phase flow in small diameter vertical tubes", *International Journal of Multiphase Flow*, 1996, 22(4), 703-712.
- Rodriguez JD, Perez A, Lozano JA, "Sensitivity analysis of k-fold cross validation in prediction error estimation", *Pattern Analysis and Machine*, 2009, 32(3), 569-575.
- Rosa E, Salgado RM, Ohishi T, Mastelari N, "Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas-liquid flows", *International Journal of Multiphase Flow*, 2010, 36(9), 738-754.
- Sebakhi E, "Flow regimes identification and liquid holdup prediction in horizontal multiphase flow based on neuro-fuzzy inference systems", *Mathematics and Computers in Simulation*, 2010, 80(9), 1854-1866.
- Shi L, "Fuzzy recognition for gas-liquid two-phase flow pattern based on image processing", *Control and Automation, IEEE International Conference on Control and Automation*, 2007, DOI: 10.1109/ICCA.2007.4376595, pp.1424-1427.
- Shi Y, Eberhart RC, "Parameter Selection in particle swarm optimization", *Evolutionary Programming*, 1998, 1447, 591-600.
- StatSoft T, "Electronic Statistics Textbook", 2007. www.statsoft.com/textbook
- Xu Y, Frang X, "A New correlation of two-phase frictional pressure drop for condensing flow in pipes", *Nuclear Engineering and Design*, 2013, 263, 87-96.
- Xu Y, Su X, Zhou Z, Chen W, "Evaluation of frictional pressure drop correlations for two-phase flow in pipes", *Nuclear Engineering and Design*, 2012, 253, 86-97.

EXTENDED ABSTRACTS

Estimation of Dynamic Pressure in Two-Phase Air-Water Flow Using ANN and ANFIS

Faezeh Moghadas^a, Abdorreza Kabiri-Samani^{a,*}, Maryam Zekri^b

^a Department of Civil Engineering, Isfahan University of Technology, Isfahan, Iran

^b Department of Electrical and Computer Engineering, Isfahan University of Technology, Isfahan, Iran

Received: 26 January 2017; Accepted: 26 August 2017

Keywords:

Air-water flow, ANN and ANFIS models, APSO algorithm, dynamic pressure, two phase flow.

1. Introduction

Two phase gas-liquid flows occur in a wide variety of situations, *i.e.*, in water supply systems, petroleum industry, pressurized tunnels and pipelines, culverts and water conduits (Mishima and Hibiki, 1996, Kabiri-Samani and Borghei, 2010). Air entrainment into a pipeline is a result of vortices at water intakes. Due to the severity of two-phase air-water flow at hydraulic systems, estimation of the dynamic pressure and pressure fluctuations in such systems is of great importance in practice (Yan et al., 2014). Most of the former studies have focused on two-phase gas-liquid flow in micro-channels and small pipelines, however, there is a lack of fundamental studies on pipelines with larger dimensions as used in hydraulic systems. Recently, some computational intelligence approaches such as ANN and ANFIS are very effectively used to predict complex problems with several parameters involved (Jang et al., 1997, Sebakhi, 2010, Fan and Yan, 2014). The present study focuses on estimation of dynamic pressure in two-phase air-water flow using ANN and ANFIS combined with PSO algorithm and subtractive clustering technique.

2. Methodology

Experiments were conducted in a horizontal/inclined air-water flow pipeline at the hydraulic laboratory of Sharif University of Technology, Iran. The setup included a 10 m long transparent pipe with an inner diameter of 90 mm. The governing dimensionless equation relating the dynamic pressure inside the pipe as a function of independent parameters is

$$\frac{h_d}{h} = f(Fr, E_0, Sh, K_f, \alpha, \bar{C}, wfs) \quad (1)$$

where h_d/h is the dimensionless dynamic pressure, Fr, E0, Sh, We, Kf, and \bar{C} are Froude number, Eotvos number, Strouhal number, Weber number, friction factor ($K_f = f_{tp}L/D$, L is a characteristic length) and averaged air concentration ($\bar{C} = \beta/(1+\beta)$, $\beta = Q_a/Q_w$) respectively. From the 302 selected data points, 70% were chosen as the training data, 20% as the checking data and the remaining 10% as the testing data to evaluate the models' performances. For better optimization of the models, the data were normalized to be in the range of [0, 1] as follows

$$X_n = (X - X_{\min}) / (X_{\max} - X_{\min}) \quad (2)$$

* Corresponding Author

E-mail addresses: f.moghadas@cv.iut.ac.ir (Faezeh Moghadas), akabiri@cc.iut.ac.ir (Abdorrezza Kabiri-Samani), mzekri@cc.iut.ac.ir (Maryam Zekri).

where x , x_n , x_{\min} and x_{\max} are the real data, normalized data, minimum and maximum values of data in each datasets. After surveying the dataset by applying the input and output variables, the developed ANN, ANN-PSO, ANFIS, ANFIS-PSO, ANFIS-SUBC, and ANFIS-PSO-SUBC models were applied to estimate the dynamic pressure in two-phase air-water flow.

3. Results and discussion

Fig. 1 compares the results of ANN and ANN-PSO for the training and testing data, whereas, Fig. 2 and Fig. 3 compare the results of ANFIS and ANFIS-PSO as well as ANFIS-SUBC and ANFIS-PSO-SUBC, respectively. Table 1 compares the results of ANN, ANN-PSO, ANFIS, ANFIS-PSO, ANFIS-SUBC and ANFIS-PSO-SUBC, models, applying NRMSE error values and R^2 for the training and checking datasets. These error functions were considered as the objective functions to tune the clustering and fuzzy antecedent and consequent parameters. According to the results, the ANFIS and the ANFIS-PSO have better recognition rate than the ANN and ANN-PSO models. Furthermore, the ANFIS models with fuzzy sub-clusters have been effectively improved the results. From Table 1, it can be concluded that the ANFIS-PSO-SUBC is apparently the best model among the developed models (NRMSE=0.19 and $R^2=0.96$) for the testing data. Figure 1 compares the results of the best predictor model (ANFIS-PSO-SUBC) with those of Kabiri-samani et al. (2007). According to this figure, ANFIS-PSO-SUBC is superior than the empirical relation given in (Kabiri-Samani et al., 2007).




Fig. 1. Results of ANFIS-PSO-SUBC compared to those of Kabiri-Samani et al. (2007)

Table 1. A comparison among the results of predictor models

Model	Train		Test	
	NRMSE	R^2	NRMSE	R^2
ANN	0.25	0.93	0.35	0.88
ANN-PSO	0.25	0.91	0.3	0.91
ANFIS	0.22	0.95	0.23	0.94
ANFIS-PSO	0.186	0.97	0.19	0.96
ANFIS-SUBC	0.228	0.95	0.23	0.92
ANFIS-PSO-SUBC	0.18	0.96	0.19	0.96

4. Conclusions

In the present study, ANN and ANFIS models have been developed to determine the dynamic pressure in two-phase air-water flow. The present models were also combined with PSO algorithm. The antecedent parameters of ANFIS were optimized, using PSO, whereas the consequent parameters were optimized, using least-square error algorithm. ANFIS includes complex processes with different parameters involved, thereby produces several rules. To overcome this complication, fuzzy clustering preprocessing was employed to decrease the number of fuzzy rules and to increase the efficiency of ANFIS. To these models with subtractive clusters, a PSO algorithm was applied to optimize the clustering parameters and to control the fuzzy- if- then rules in subtractive clustering. Another PSO algorithm was also employed to tune the fuzzy rule parameters associated with fuzzy if-then rules. The SUBCLUST fuzzy clustering technique was applied for estimating the variation of dynamic pressure in two-phase air-water flows. Performances of the models were evaluated using

RMSE, NRMSE, and R^2 . Results show that the ANFIS model is more accurate than the empirical correlations presented in the literature. Furthermore, by combining the ANFIS model with PSO algorithm and the subtractive fuzzy clustering technique, the results were improved significantly.

5. References

- Mishima K, Hibiki T, "Some characteristics of air-water two-phase flow in small diameter vertical tubes", *International Journal of Multiphase Flow*, 1996, 22(4), 703-712.
- Kabiri-Samani AR, Borghei SM, "Pressure loss in a horizontal two-phase slug flow", *Journal of Fluids Engineering*, 2010, 132(7), 1-8.
- Yan C, Yan C, Sun L, Wang Y, Zhang X, "Slug behavior and pressure drop of adiabatic slug flow in a narrow rectangular duct under inclined conditions", *Annals of Nuclear Energy*, 2014, 64, 21-31.
- Sebakhi E, "Flow regimes identification and liquid holdup prediction in horizontal multiphase flow based on neuro-fuzzy inference systems", *Mathematics and Computers in Simulation*, 2010, 80(9), 1854-1866.
- Fan S, Yan T, "Two-phase air-water slug flow measurement in horizontal pipe using conductance probes and neural networks", *IEEE Transaction on Instrumentation and Measurement*, 2014, 63(2), 456-466.
- Jang JSR, Sun CT, Mizutani E, "Neuro-Fuzzy modeling and soft computing", Prentice Hall, Englewood Cliffs, 1997.
- Kabiri-Samani AR, Borghei SM, Saidi MH, "Fluctuation of air-water two-phase flow in horizontal and inclined water pipelines", *Journal of Fluids Engineering*, ASME, 2007, 129(1), 1-14.