Journalof Farayandno – Vol. 19 – No.87 (2024): 85-93

Review Article

DOI: 10.22034/farayandno.2025.2045358.1976

This journal is an open access journal licensed under an Attribution-Non Commercial 4.0 International Licenses (CC BY-NC 4.0).

Estimating Economical Thermal Insulation Thickness Using Artificial Intelligence Approach

Alireza Baghban [1*], Mohammadreza Kazemi [2]

[1] Production Management, Gas & Natural Gas Liquid Engineering Department, National Iranian South Oilfields Company (NISOC), Ahvaz, Iran

[2] Process Engineering Department, Bandar Imam Petrochemical Company (BIPC), Mahshahr, Iran

Received: 10 Aug 2024 **Accepted:** 20 Oct 2024

Abstract

Due to the complexities in industrial processes and the variety of environmental conditions, it is necessary to use advanced methods to determine the insulation thickness. This study examines the use of artificial neural networks to predict the thickness of thermal insulation. In this regard, first, the thermal insulation data available in Iranian Petroleum Standard (IPS) with the code IPS-E-TP-700, is collected, and then the thickness of the insulation is predicted as a function of the outer diameter, thermal conductivity of the insulation and surface temperature. The statistical results show the high accuracy of the method used in predicting the thickness of the insulation, and the value of the regression coefficient and the relative error percentage for the tested data are 1.000 and 0.19, respectively. This approach not only helps to optimize insulation processes, but can also lead to cost reduction and increased safety in industrial operations.

Keyword: Artificial neural network, Insulation, Machine learning, Oil and gas industry, Modeling

* baghban1369@gmail.com

Please Cite This Article Using:

Baghban, A., Kazemi, M., “Estimating Economical Thermal Insulation Thickness Using Artificial Intelligence Approach”, Journal of Farayandno – Vol. 19 – No. 87, pp. 85-93, In Persian, (2024).

نشریه فرآیندنو، سال نوزدهم، شماره 87، صص 93-85 (پاییز 1403)

مقاله ترویجی

DOI: 10.22034/farayandno.2025.2045358.1976

This journal is an open access journal licensed under an Attribution-Non Commercial 4.0 International Licenses (CC BY-NC 4.0).

پیش‌بینی ضخامت بهینه عایق حرارتی لوله و تجهیزات فرآیندی با استفاده از روش‌های هوشمند

علیرضا باغبان [1*]، محمدرضا کاظمی [2]

[1] شرکت ملی مناطق نفتخیز جنوب، مدیریت تولید، امور مهندسی گاز و گازمایع، اهواز، ایران

[2] شرکت پتروشیمی بندر امام، مجتمع فرآورش دو، اداره مهندسی فرایند، ماهشهر، ایران

دریافت: 1403/05/20 پذیرش: 1403/07/29

چکیده

پیش‌بینی ضخامت عایق‌های حرارتی تجهیزات در صنعت نفت و گاز به عنوان یک عامل کلیدی در بهینه‌سازی عملکرد و کاهش هزینه‌های انرژی شناخته می‌شود. این مطالعه به بررسی استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی ضخامت عایق‌های حرارتی می‌پردازد. در این خصوص ابتدا داده های عایق های حرارتی موجود در استاندارد نفت ایران با کد IPS-E-TP-700، جمع آوری و سپس ضخامت عایق به صورت تابعی از قطر بیرونی، هدایت حرارتی عایق و دمای سطح پیش بینی می گردد. نتایج آماری نشان از دقت بالای روش استفاده شده در پیش‌بینی ضخامت عایق را دارد و مقدار ضریب رگراسیون و درصد خطای نسبی برای داده های تست شده به ترتیب 1/000 و 0/19 می‌باشد. این رویکرد نه تنها به بهینه‌سازی فرآیندهای عایق‌بندی کمک می‌کند، بلکه می‌تواند به کاهش هزینه‌ها و افزایش ایمنی در عملیات صنعتی نیز منجر شود.

کلمات کلیدی: شبکه عصبی مصنوعی، عایق، یادگیری ماشین، صنعت نفت و گاز، مدلسازی

* baghban1369@gmail.com

استناد به مقاله:

باغبان،ع.، کاظمی،م.ر.،"پیش‌بینی ضخامت بهینه عایق حرارتی لوله و تجهیزات فرآیندی با استفاده از روش‌های هوشمند"، نشریه فرآیندنو، سال نوزدهم، شماره 87، صص.93-85، (پاییز 1403).

1- مقدمه

عایق‌های حرارتی به عنوان یکی از اجزای اساسی در صنعت نفت و گاز، نقش کلیدی در بهینه‌سازی مصرف انرژی، حفظ دما و افزایش ایمنی تجهیزات ایفا می‌کنند [2, 1]. با توجه به اینکه فرآیندهای استخراج، پالایش و انتقال نفت و گاز معمولاً در دماهای بالا و شرایط سخت انجام می‌شود، استفاده از عایق‌های حرارتی مناسب می‌تواند به طور قابل توجهی از اتلاف حرارت جلوگیری کرده و کارایی سیستم‌ها را افزایش دهد [4, 3]. در دنیای امروز، با افزایش نگرانی‌ها در مورد تغییرات اقلیمی و نیاز به کاهش مصرف انرژی، اهمیت عایق‌بندی در صنایع مختلف، به ویژه در صنعت نفت، بیش از پیش نمایان شده است. عایق‌های حرارتی نه تنها به کاهش هزینه‌های عملیاتی کمک می‌کنند، بلکه به حفظ دما در محدوده‌های مطلوب برای فرآیندهای صنعتی نیز کمک می‌نمایند. این امر به ویژه در مورد تجهیزات حساس مانند مخازن، لوله‌ها و کوره‌ها که در معرض دماهای بالا و نوسانات دمایی قرار دارند، اهمیت دارد[6, 5]. علاوه بر این، عایق‌بندی مناسب می‌تواند به کاهش خطرات ناشی از دماهای بالا، مانند آتش‌سوزی و انفجار، کمک کند. در صنعت نفت، که با مواد قابل اشتعال و خطرناک سروکار دارد، ایمنی یکی از اولویت‌های اصلی است. بنابراین، انتخاب و نصب عایق‌های حرارتی مناسب می‌تواند به طور مستقیم بر ایمنی کارکنان و تجهیزات تأثیر بگذارد. عایق‌های حرارتی در انواع مختلفی تولید می‌شوند که هر کدام ویژگی‌ها و کاربردهای خاص خود را دارند. از عایق‌های معدنی مانند پشم سنگ و پشم شیشه گرفته تا عایق‌های ارگانیک مانند فوم‌های پلی‌یورتان و پلی‌استایرن، هر یک از این مواد به دلیل ویژگی‌های خاص خود در شرایط مختلف مورد استفاده قرار می‌گیرند [6, 2]. عایق‌های معدنی به دلیل مقاومت در برابر حرارت و آتش‌سوزی، در تجهیزات پالایشگاهی و کوره‌ها به کار می‌روند، در حالی که عایق‌های ارگانیک به دلیل وزن سبک و کارایی حرارتی خوب، در عایق‌بندی لوله‌ها و مخازن استفاده می‌شوند [6]. تعیین ضخامت مناسب عایق حرارتی یکی از چالش‌های مهم در طراحی و اجرای سیستم‌های عایق‌بندی است. این فرآیند نیازمند در نظر گرفتن عوامل متعددی از جمله نوع عایق، دماهای عملیاتی، نوع سیال و استانداردهای صنعتی است [8, 6]. محاسبات دقیق حرارتی و استفاده از نرم‌افزارهای تخصصی می‌تواند به مهندسان کمک کند تا ضخامت بهینه عایق را تعیین کنند و از این طریق به حداکثر کارایی و ایمنی دست یابند. در این راستا، عایق‌بندی حرارتی نه تنها به عنوان یک راهکار اقتصادی برای کاهش هزینه‌های انرژی، بلکه به عنوان یک ابزار حیاتی برای حفظ ایمنی و کارایی در صنعت نفت و گاز شناخته می‌شود. با توجه به اهمیت روزافزون مسائل زیست‌محیطی و اقتصادی، این موضوع نه تنها برای مهندسان و متخصصان صنعت نفت، بلکه برای سیاست‌گذاران و محققان نیز حائز اهمیت است.

پیش‌بینی ضخامت عایق‌های حرارتی با استفاده از شبکه‌های عصبی مصنوعی یکی از موضوعات جالب و جدید در حوزه علوم مرتبط با صنعت نفت و گاز است. شبکه‌های عصبی مصنوعی به عنوان یک ابزار قدرتمند در یادگیری ماشین، قابلیت مدل‌سازی روابط پیچیده و غیرخطی بین ورودی‌ها و خروجی‌ها را دارند. امروزه روش های هوشمند کاربردهای وسیعی در علوم مهندسی بویژه دانش مرتبط با مهندسی شیمی و نفت دارد [15- 9]. با استفاده از داده‌های تجربی و شبیه‌سازی‌های عددی، می‌توان شبکه‌های عصبی را آموزش داد تا ضخامت بهینه عایق‌های حرارتی را پیش‌بینی کنند. این روش می‌تواند به مهندسان و طراحان کمک کند تا تصمیمات بهتری در زمینه انتخاب مواد و طراحی سیستم‌های حرارتی اتخاذ کنند.

در این مطالعه ابتدا دیتاهای مربوط به ضخامت بهینه عایق‌های حرارتی بر اساس تابعی از قطر خارجی، دمای سطح و هدایت حرارتی عایق از استاندارد IPS اخذ [6] و سپس با استفاده از روش شبکه عصبی مصنوعی، ضخامت بهینه عایق تخمین زده شده است.

2. تئوری شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی از نورون‌های بیولوژیکی در بدن انسان الهام گرفته شده‌اند که تحت شرایط خاصی فعال می‌شوند و در نتیجه عمل مرتبطی انجام می‌شود. شبکه‌های عصبی مصنوعی از لایه‌های مختلفی از نورون‌های مصنوعی به هم پیوسته تشکیل شده‌اند که با توابع فعال‌سازی تغذیه می‌شوند که به روشن/خاموش کردن آن‌ها کمک می کند [17, 16]. به‌طور خلاصه، هر نورون یک نسخه ضرب‌شده از ورودی‌ها و وزن‌های تصادفی دریافت می‌کند که با یک مقدار بایاس استاتیک (که برای هر لایه نورون منحصر به فرد است) اضافه می‌شود. سپس به یک تابع فعال‌سازی مناسب منتقل می‌شود که مقدار نهایی را که باید از نورون داده شود، تعیین می‌کند. بر اساس ماهیت مقادیر ورودی، توابع فعال سازی مختلفی وجود دارد. هنگامی که خروج از لایه شبکه عصبی نهایی تولید می‌شود، تابع تلفات یا خطا (ورودی در مقابل خروجی) محاسبه می‌شود و پس انتشار طوری انجام می‌شود که وزن‌ها برای حداقل خطا تنظیم شوند. یافتن مقادیر بهینه وزن‌ها در شبکه عصبی همان چیزی است که عملیات کلی روی آن متمرکز است. نحوه ساختار بندی یک شبکه عصبی، در شکل 1 نشان داده شده است.

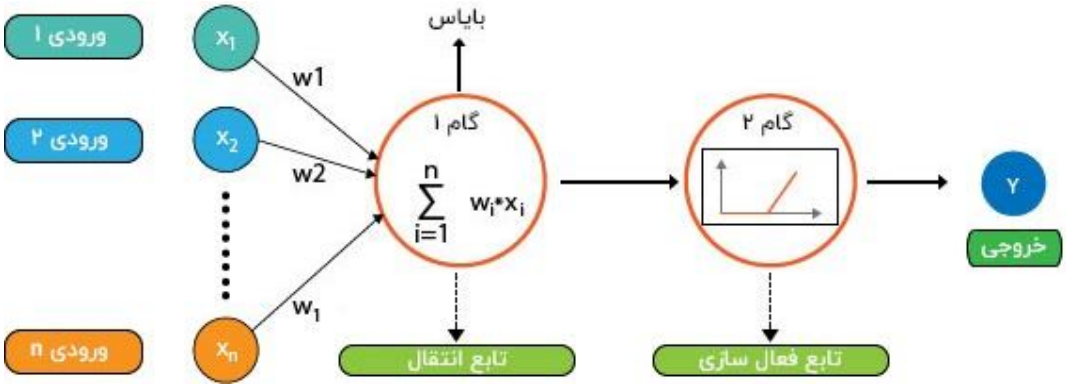

شکل 1- اجزای شبکه عصبی مصنوعی

اجزای شبکه نشان داده شده شامل:

- **وزن‌ها:** وزن‌ها مقادیر عددی هستند که در ورودی‌ها ضرب می‌شوند. به عبارت ساده، وزن‌ها مقادیری هستند که از طریق شبکه‌های عصبی توسط ماشین یاد می‌شوند. وزن‌ها بسته به تفاوت بین خروجی‌های پیش‌بینی شده در مقابل ورودی‌های آموزشی خود تنظیم می‌شوند.
- **تابع فعال سازی:** تابع فعال سازی یک فرمول ریاضی است که به نورون کمک می‌کند تا روشن یا خاموش شود.
- **لایه ورودی**: لایه ورودی ابعاد بردار ورودی را نشان می‌دهد.

- **لایه پنهان:** لایه پنهان نشان دهنده گره‌های واسطه‌ای است که فضای ورودی را به مناطقی با مرزهای (نرم) تقسیم می‌کنند. مجموعه‌ای از ورودی وزن دار را می‌گیرد و از طریق یک تابع فعال سازی خروجی تولید می‌کند.
- **لایه خروجی:** لایه خروجی نشان دهنده خروجی شبکه عصبی است.

3- روش مدلسازی

3-1- داده های استفاده شده:

داده‌های استفاده شده در این پژوهش از استاندارد IPS-E-TP-700 گرفته شده است [6]. در این استاندارد تعداد 768 داده وجود داشته که شامل اطلاعات قطر خارجی (میلی متر)، دمای سطح (درجه سلسیوس)، هدایت حرارتی عایق (W/m.K) و ضخامت عایق (میلی متر) ارائه شده است. محدوده متغیرهای موجود در شکل 2 نشان داده شده است. ذکر این نکته ضروریست که داده‌های مربوط به دمای سطح 300 و 600 درجه سانتیگراد به عنوان داده‌های تست درنظر گرفته شد تا بتواند به خوبی مدل را ارزیابی نماید.

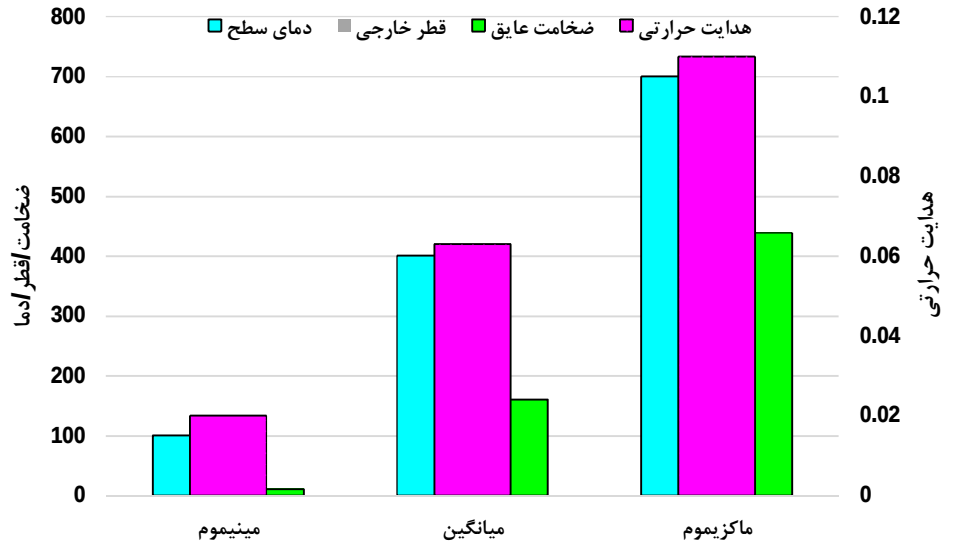

شکل 2- محدوده متغیرهای مورد استفاده جهت ساخت مدل

3-2- ساخت شبکه

به منظور انجام مدلسازی با روش شبکه عصبی مصنوعی، نرم افزار متلب ورژن 2016 استفاده گردید. در این خصوص ابتدا داده‌های ورودی به دو دسته آموزش و تست تقسیم بندی شدند. داده‌های مربوط به دمای سطح 300 و 600 درجه سلسیوس جهت تست عملکرد مدل و مابقی داده‌ها جهت آموزش آن بکار گرفته شدند. در این مطالعه تعداد نورون‌های موجود در لایه پنهان شبکه عصبی مصنوعی 10 عدد در نظر گرفته شد و پارامترهای وزن و بایاس با الگوریتم لونبرگ-مارکواردت بهینه سازی شدند. پس از ساخت مدل، به منظور بررسی عملکرد آن ارزیابی‌های آماری مختلفی همچون ضریب رگراسیون، درصد خطای نسبی و میانگین مربعات خطا صورت پذیرفت.

4. نتایج و بحث

در شکل 3 ضخامت بهینه عایق بر اساس داده‌های واقعی و داده‌های پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی نشان داده شده است. همانطور که مشخص است اختلاف مقادیر واقعی و پیش‌بینی شده بسیار ناچیز بوده و مدل حاضر توانسته است به خوبی مقدار ضخامت عایق را پیش‌بینی نماید.

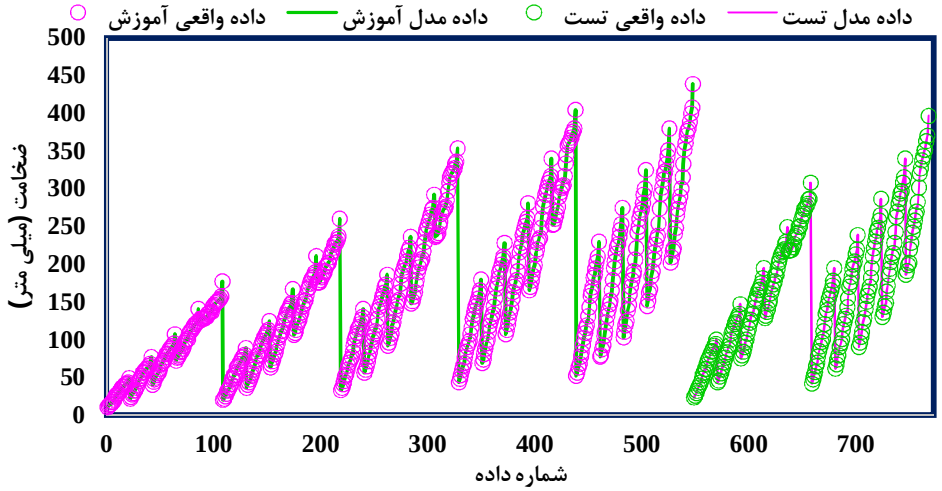

شکل 3- نمایش همزمان ضخامت عایق بدست آمده از مدل و مقدیر واقعی آن

همچنین نمودار رگراسیون مدل شبکه عصبی برای داده‌های تست و آموزش در شکل 4 ارائه شده است. ضریب رگراسیون بدست آمده برای هر دو گروه تست و آموزش 1/000 بوده است و نشان از دقت بالای مدل ارائه شده دارد.

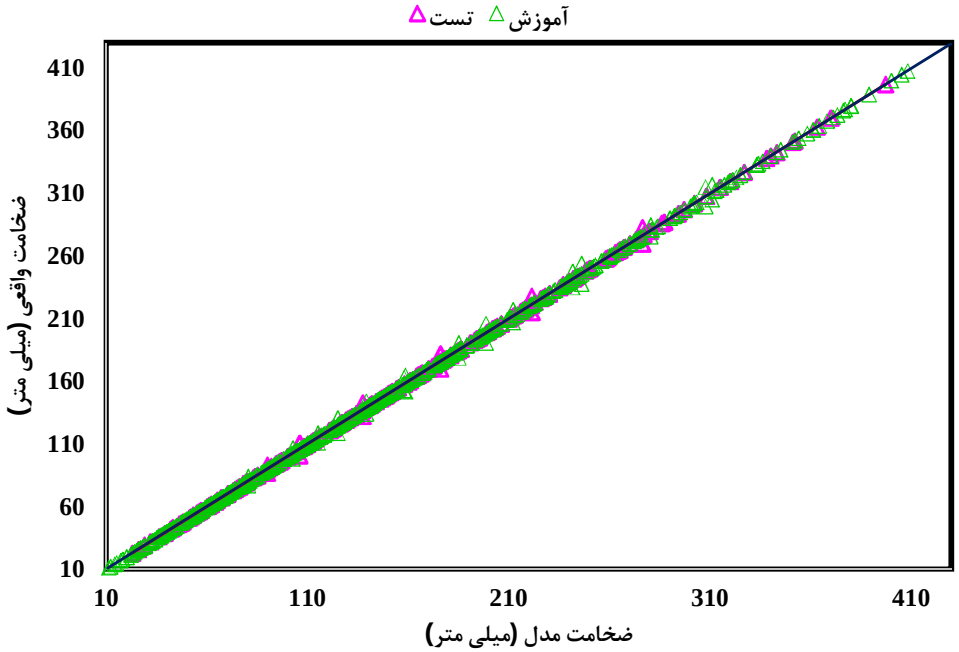

شکل 4- نمودار رگراسیون بین داده‌های واقعی و مدل شبکه عصبی

معادله خط بین داده‌های واقعی و مدل برای هر دو گروه تست و آموزش به صورت زیر بدست آمده است.

$$y = x - 0.0015 \quad (1)$$

در این فرمول x خروجی مدل و y مربوط به داده‌های واقعی می‌باشد که بسیار نزدیک به خط y=x می‌باشد.
در شکل 5 نیز درصد خطای نسبی مدل قابل مشاهد می‌باشد و همانگونه که مشخص است این خطا در محدوده 5 درصد می‌باشد.

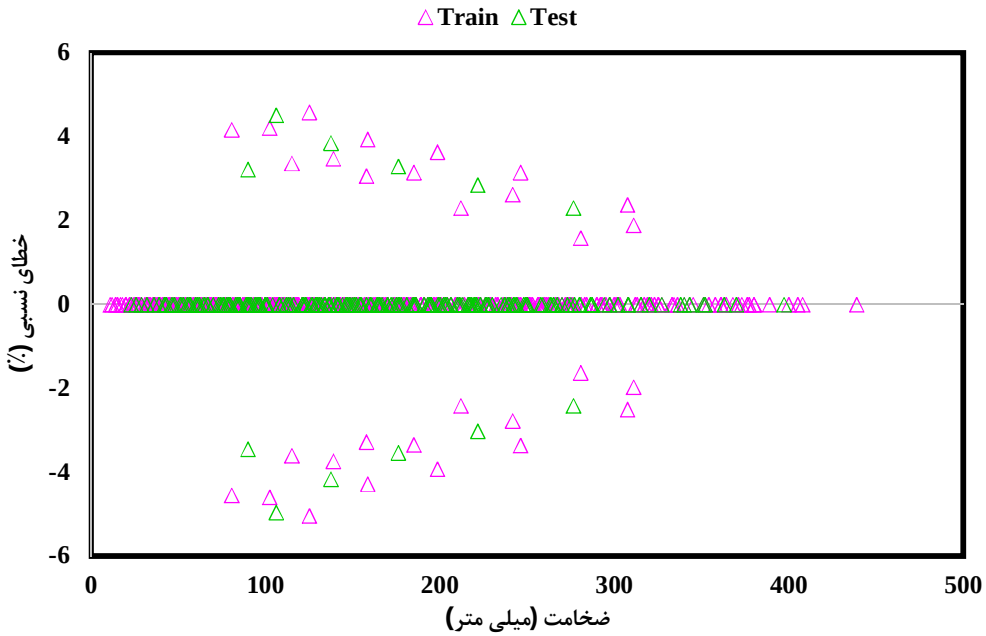

شکل 5- نمودار درصد خطای نسبی داده‌های واقعی و مدل شبکه عصبی

در جدول 1 ارزیابی آماری مدل شبکه عصبی ارائه شده است و همانگونه که مشخص است دقت مدل ارائه شده بسیار بالا بوده و با داده‌های واقعی تطابق بسیار عالی داشته است.

جدول 1- ارزیابی آماری مدل شبکه عصبی

گروه	میانگین مربعات خطا	ضریب رگراسیون (R^2)	درصد خطای نسبی
گروه تست	1/98	1/00	**0/19**
گروه آموزش	1/78	1/00	**0/20**
کل داده‌ها	1/93	1/00	**0/19**

در جدول 2 مقایسه بین مقادیر پیش‌بینی شده مدل شبکه عصبی و رابطه تجربی بهادری و همکارانش [8] ارائه شده است. همانگونه که مشخص است دقت روش حاضر بسیار بالاتر از رابطه تجربی می‌باشد.

جدول 2- مقایسه مقادیر پیش‌بینی شده مدل حاضر و مدل بهادری و همکارانش

ضخامت بهینه تخمینی (روش بهادری و همکاران)		ضخامت بهینه تخمینی (مطالعه حاضر)		ضخامت بهینه (میلی متر)	قطر خارجی (میلیمتر)	هدایت حرارتی	دمای سطح
درصد خطا	مقدار پیش‌بینی	درصد خطا	مقدار پیش‌بینی				
1/19	31/37	0/0043	31/00133	31	168/3	0/02	100
1/79	55	0/0019	56/001	56	114/3	0/03	300
1/11	89	0/00082	90/00	90	101/6	0/05	500
2/34	209	0/0002	213/99	214	273	0/08	700

به منظور بررسی تاثیر پارامترهای ورودی بر روی ضخامت بهینه عایق، روش SHAP بکار گرفته شد. تحلیل SHAP یک روش برای تفسیر خروجی مدل‌های یادگیری ماشین است. این روش به ما کمک می‌کند تا درک کنیم هر ویژگی چگونه به پیش‌بینی مدل کمک می‌کند. چارچوب SHAP بر اساس نظریه بازی‌های تعاونی و به‌ویژه ارزش شاپلی است که به طور عادلانه "پاداش" (در اینجا پیش‌بینی مدل) را بین ویژگی‌ها توزیع می‌کند. شکل 6، نمودار مربوط به تحلیل SHAP می باشد و همانطور که مشخص است، تغییرات هدایت حرارتی بیشترین تاثیر را بر روی خروجی دارد.

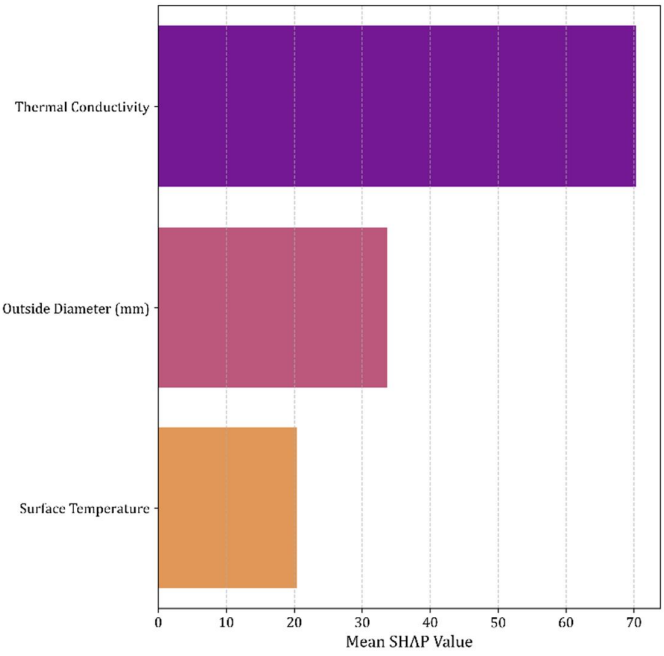

شکل 6- تحلیل SHAP جهت بررسی تاثیر پارامترهای ورودی

5- نتیجه‌گیری

پیش‌بینی ضخامت عایق‌های حرارتی تجهیزات در صنعت نفت و گاز به عنوان یک عامل کلیدی در بهینه‌سازی عملکرد و کاهش هزینه‌های انرژی شناخته می‌شود. در این مطالعه ضخامت عایق‌های حرارتی به صورت تابعی از قطر بیرونی، هدایت حرارتی عایق و دمای سطح با استفاده از شبکه عصبی مصنوعی پیش‌بینی گردید. پارامترهای مدل ساخته

شده شامل وزن و بایاس می باشند که از طریق الگوریتم لونبرگ-مارکواردت به طور بهینه تعیین شدند. نتایج آماری و نمودارهای ارائه شده نشان از دقت بالای روش استفاده شده در پیش‌بینی ضخامت عایق را دارد و مقدار ضریب رگراسیون و درصد خطای نسبی برای داده‌های تست شده به ترتیب 1/000 و 0/19 می باشد. این رویکرد نه تنها به بهینه‌سازی فرآیندهای عایق‌بندی کمک می‌کند، بلکه می‌تواند به کاهش هزینه‌ها و افزایش ایمنی در عملیات صنعتی نیز منجر شود.

6- منابع

[1] Zach J, Hroudová J, Brožovský J, Krejza Z, Gailius A. Development of thermal insulating materials on natural base for thermal insulation systems. Procedia Eng.;57: pp. 94–1288, 2013.
[2] Villasmil W, Fischer LJ, Worlitschek J. A review and evaluation of thermal insulation materials and methods for thermal energy storage systems. Renew Sustain Energy Rev.;103: pp. 71–84, 2019.
[3] Tychanicz-Kwiecień M, Wilk J, Gil P. Review of high-temperature thermal insulation materials. J Thermophys Heat Transf ;33: pp. 84–271, 2019.
[4] Abdullaev AR, Zulxumor INQ. A Review On: Analysis Of The Properties Of Thermal Insulation Materials. Am J Interdiscip Innov Res ;3: pp. 27–38, 2021.
[5] Lee SW, Lim CH. Reflective thermal insulation systems in building: A review on radiant barrier and reflective insulation. Renew Sustain Energy Rev;65: pp. 61–643, 2016.
[6] Standard IP. Engineering standard for thermal insulations. Rep IPS-E-TP-700, Natl Iran Oil Company, Ahwaz, Iran 1996.
[7] Keçebaş A, Alkan MA, Bayhan M. Thermo-economic analysis of pipe insulation for district heating piping systems. Appl Therm Eng ;31: pp. 37–3929, 2011.
[8] Bahadori A, Vuthaluru HB. A simple correlation for estimation of economic thickness of thermal insulation for process piping and equipment. Appl Therm Eng ;30: pp. 9–254, 2010.
[9] Ahmadi MH, Baghban A, Sadeghzadeh M, Hadipoor M, Ghazvini M. Evolving connectionist approaches to compute thermal conductivity of TiO<inf>2</inf>/water nanofluid. Phys A Stat Mech Its Appl; pp. 540, 2020.
[10] Dashti A, Raji M, Azarafza A, Baghban A, Mohammadi AH, Asghari M. Rigorous prognostication and modeling of gas adsorption on activated carbon and Zeolite-5A. J Environ Manage ;224: pp. 58–68, 2018.
[11] Baghban A, Kardani MN, Habibzadeh S. Prediction viscosity of ionic liquids using a hybrid LSSVM and group contribution method. J Mol Liq ;236: pp. 452–64, 2017.
[12] Baghban A, Ahmadi MA, Pouladi B, Amanna B. Phase equilibrium modeling of semi-clathrate hydrates of seven commonly gases in the presence of TBAB ionic liquid promoter based on a low parameter connectionist technique. J Supercrit Fluids; pp. 101, 2015.
[13] Eghtedaei R, Sasanipour J, Zarrabi H, Palizian M, Baghban A. Estimation of wax deposition in the oil production units using RBF-ANN strategy. Pet Sci Technol; pp. 35, 2017.
[14] Bahadori A, Baghban A, Bahadori M, Kashiwao T, Ayouri MV. Estimation of emission of hydrocarbons and filling losses in storage containers using intelligent models. Pet Sci Technol; pp. 34, 2016.
[15] Baghban A, Kahani M, Nazari MA, Ahmadi MH, Yan W-M. Sensitivity analysis and application of machine learning methods to predict the heat transfer performance of CNT/water nanofluid flows through coils. Int J Heat Mass Transf ;128: pp. 825–35, 2019.
[16] Mitchell TM. Artificial neural networks. Mach Learn ;45: pp. 81–127, 1997.
[17] Schalkoff RJ. Artificial neural networks. vol. 1. McGraw-Hill New York; 1997.