



## افزایش بهره‌وری انرژی با رویکرد LCA: مطالعه موردی دامداری

عسل سیدآقا

کارشناسی ارشد مهندسی صنایع، دانشگاه علم و فرهنگ

علی قرقی

پژوهشگر ارشد در دانشگاه کاردیف انگلستان

علیرضا ممجد

دکتری مدیریت بازاریابی ورزشی، دانشگاه آزاد تهران مرکز

### چکیده

با توجه به آنکه نگهداری دام سهم به سزایی در گرمایش جهانی و آلودگی زیست محیطی دارد، چرخه زندگی نگهداری گاو و گوساله و تولید محصولات لبنی در یک دامداری در ایران مورد بررسی و بهبود قرار گرفت. در این مقاله، ما از مدل شبکه عصبی مصنوعی (ANN) استفاده کردیم و سپس توسط الگوریتم ژنتیک (GA) به عنوان تابع ارزیابی تناسب برای به دست آوردن جواب بهینه مورد استفاده قرار گرفت. این رویکرد بهینه‌سازی منجر به صرفه‌جویی انرژی قابل ملاحظه‌ای حدود ۳۲٪ نسبت به سناریوی پایه شد. نتایج حاصل از این مدل‌ها سپس به مدل ارزیابی چرخه حیات (LCA) اضافه شدند تا تأثیرات زیست محیطی و بهره‌وری انرژی مرتبط با مصرف برق در تجهیزات زمستانی و روشنایی دامداری را ارزیابی کنند. این به بهبود برخی از پارامترهای LCA منجر شد و برای تصمیم‌گیری که به هدف اجرای روش‌های محیط‌زیستی پایدارتر اقدام می‌کنند، ابزارهای ارزشمندی فراهم می‌آورد. به علاوه، این مطالعه بر توانمندی یادگیری ماشین (ML) و تکنیک‌های بهینه‌سازی در کاهش اثرات زیست محیطی مرتبط با مصرف برق دامداری از طریق افزایش بهره‌وری انرژی تأکید می‌کند.

**واژگان کلیدی:** ارزیابی چرخه حیات- یادگیری ماشین- شبکه‌های عصبی مصنوعی- دامداری - الگوریتم ژنتیک



## مقدمه

تولید دامی بخش اساسی از سیستم تغذیه جهانی است که پروتئین‌های اساسی (شیر، تخم‌مرغ و گوشت) را در سراسر جهان فراهم می‌کند، به بهره‌وری محصولات کشاورزی از طریق استفاده از کود حیوانی کمک کرده و تغذیه و درآمد حیاتی برای خانواده‌های فقیر در کشورهای با درآمد کم تا متوسط فراهم می‌آورد (Robinson et al, 2011; Gilbert et al, 2018).

با توجه به ادبیات کنونی، تولید شیر خام در میان زنجیره تأمین پیچیده لبنیات، به عنوان مهمترین عامل موثر در تأثیرات زیست‌محیطی کل زنجیره لبنیات محسوب می‌شود (Finnegan et al, 2018) با مشارکت کلی در انتشار گازهای گلخانه‌ای در سطح جهان به میزان ۲.۷٪، شامل تولید شیر و حمل‌ونقل آن (FAO, 2010) بر اساس تحلیل ۲۶ مطالعه توسط گزمن همکاران در سال ۲۰۲۲، مزارع لبنیات به عنوان منبع اصلی انتشار گازهای گلخانه‌ای در صنعت لبنیات مشخص شده‌اند که مسئول حدود ۸۰٪ از کل اثر کربن لبنیات هستند (Guzmán-Luna et al, 2022). با افزایش سریع جمعیت جهان، پیش‌بینی می‌شود که تقاضا برای شیر و محصولات لبنی افزایش یابد. این رشد در تقاضا احتمالاً تأثیرات زیست‌محیطی قابل ملاحظه‌ای داشته باشد، به‌ویژه از نظر تولید گاو در صنعت لبنیات (GDP, 2018). افراد متخصص در زمینه تغییرات آب و هوا به این نتیجه رسیده‌اند که علاوه بر استراتژی‌های کاهشی، استراتژی‌های سازگاری با تغییرات آب و هوایی نیز برای مقابله با چالش‌های ایجاد شده توسط گرمای جهانی اساسی هستند. این توافق به علت درک این است که حتی اگر انتشارات انسانی به طور ناگهانی متوقف شود، آب و هوا همچنان تغییر خواهد کرد. با توجه به آن که، چند دهه زمان نیاز است تا تلاش‌های کاهش تأثیر دمای افزایش یافته به طور قابل توجهی اثر گذار باشند، ضروری است که سیستم‌های جهانی به‌گونه‌ای بازسازی شوند تا تغییراتی که در حال حاضر و در آینده قابل پیش‌بینی است را دربرگیرند. این ممکن است شامل توسعه و پذیرش استراتژی‌هایی در تمامی سیستم‌های توسعه جهانی باشد تا انطباق و افزایش انعطاف‌پذیری در مقابل تغییرات آب و هوا ایجاد شود (Wang et al, 2023). تخمین دقیق‌تر گازهای گلخانه‌ای از طریق ارزیابی چرخه حیات<sup>۱</sup> (LCA) امکان‌پذیر است که تمام منابع مهم انتشار و حذف در سیستم تولید را شامل می‌شود، از جمله منابع مرتبط با تولید منابع مورد استفاده در سیستم. (Rotz et al, 2010)

انرژی نقش حیاتی را به عنوان یک منبع ضروری و یک هزینه قابل ملاحظه در عملیات دامداری دارد. انرژی مورد استفاده در سیستم‌های لبنیات را می‌توان به ورودی‌های مستقیم و غیرمستقیم تقسیم کرد. این ورودی‌های انرژی به‌طور قابل توجهی به هر دو مصرف مستقیم و غیرمستقیم انرژی فسیلی کمک می‌کنند و منجر به ایجاد انتشار دی‌اکسید کربن (CO<sub>2</sub>) می‌شوند، هم در مزرعه خود و هم در سیاق خارج از مزرعه (Todde et al, 2018; Ilyas et al, 2020). بر اساس مقاله خالقی و همکاران، (۲۰۲۳)، سهم مصرف الکتریسیته دستگاه سرمایش شیر ۲۸.۹٪ از کل تجهیزات مصرف‌کننده الکتریسیته در دامداری است (Khaleghy et al, 2023). الیاس و همکاران پیشنهاد داده‌اند که برای افزایش بهره‌وری انرژی در سیستم‌های لبنیات، ترکیبی از ارزیابی‌های انرژی،

<sup>1</sup> Life cycle assessment



افزایش استفاده از منابع انرژی تجدیدپذیر و اجرای فناوری کشاورزی دقیق باید پیگیری شود (Ilyas et al, 2020). شبکه‌های عصبی مصنوعی<sup>2</sup> (ANN) دسته‌ای از الگوریتم‌های محاسباتی یادگیری ماشین هستند که به طور گسترده برای مقابله با چالش‌ها و پیش‌بینی مسائل متنوع استفاده می‌شوند (Sharafi et al, 2023). در مطالعه‌ای انجام شده توسط خوشرو و همکاران در سال ۲۰۱۸، مدل‌های ANN برای پیش‌بینی عملکرد انرژی بر اساس انرژی‌های ورودی ایجاد شدند. تحقیقات آنان شامل منابع مستقیم ورودی انرژی (مانند نیروی کار، سوخت، الکتریسیته و آب) و منابع غیرمستقیم (مانند کود حیوانی، مواد شیمیایی و ماشین‌آلات) به عنوان عوامل در مدل‌های پیش‌بینی آنها بود. سفیدپری و همکاران از یک سیستم استنتاج فازی تطبیقی با استفاده از داده‌های ۵۰ مزرعه ایرانی استفاده کردند (Sefeedpari et al, 2014). در یک مطالعه دیگر، از یک شبکه‌ی عصبی مصنوعی (ANN) استفاده کردند (Sefeedpari et al, 2013). شاین و همکاران در سال ۲۰۱۸ یک مدل ماشین پشتیبان برای پیش‌بینی مصرف الکتریسیته سالیانه در سطح مزرعه و حوزه‌ی دامداری ایجاد کردند (Shine et al, 2018). در یک مطالعه دیگر، از الگوریتم‌های مختلف یادگیری ماشین برای پیش‌بینی مصرف آب و الکتریسیته در ۵۸ مزرعه‌ی لبنیات مبتنی بر چرای مرتع استفاده کردند. شبکه‌های عصبی مصنوعی (ANNs) از مجموعه داده‌های قبلی برای آموزش استفاده می‌کنند و توانایی تقلید از توابع غیرخطی و ارتباطات پیچیده بین متغیرها را مانند سیستم عصبی انسان دارند. پس از آموزش بر داده‌های تاریخی، شبکه‌های عصبی مصنوعی موثر در پیش‌بینی مصرف یا تولید انرژی هستند (Ghoroghi et al, 2023). علاوه بر این، مدل‌های ترکیبی که ترکیب شبیه‌سازی انرژی و الگوریتم‌های ژنتیک (GAs) را شامل می‌شوند، در انتخاب پارامترهای طراحی بهینه و افزایش کارایی انرژی موثر هستند (Howell et al, 2018; Ferdyn-Grygiere and Grygierek, 2017; Yuce and Rezgui, 2015; Reynold et al, 2019). ژنتیک‌ها به طور مکرر برای وظایفی نظیر طراحی ساختار شبکه‌های عصبی یا بهبود نرخ یادگیری آنها استفاده می‌شوند (Ghoroghi et al, 2023). شارما و همکاران در سال ۲۰۲۲ از الگوریتم‌های ژنتیک برای بهینه‌سازی وزن‌های شبکه‌های عصبی مصنوعی برای بهبود دقت نتایج تولید شده توسط شبکه‌های عصبی مصنوعی و کمینه کردن خطاهای پیش‌بینی استفاده کردند (Sharma et al, 2022).

هدف اصلی این مطالعه ایجاد یک مدل شبکه عصبی مصنوعی (ANN) است که با در نظر گرفتن ورودی‌های انرژی مورد استفاده در یک دامداری واقع در استان دماوند، ایران، تخمین دقیقی از خروجی انرژی ارائه دهد. پس از آن، یک روش بهینه برای مصرف انرژی، با استفاده از الگوریتم ژنتیک<sup>3</sup> (GA)، در مرحله تولید مورد مطالعه ما تعیین و یک راه‌حل برای کاهش مصرف انرژی دامداری ارائه خواهد شد. در نهایت، شاخص‌های محیطی قبل و بعد از بهینه‌سازی توسط LCA مقایسه خواهند شد.

<sup>2</sup> Artificial Neural Networks

<sup>3</sup> Genetic Algorithm



## روش تحقیق

### مطالعه موردی و جمع‌آوری داده

ورامین یک شهر واقع در ایران است که در جنوب استان تهران واقع شده و در منطقه وسط شمالی کشور قرار دارد. تهران، پایتخت ایران، به شمال ورامین واقع شده و فاصله تقریبی آن حدود ۳۵ کیلومتر (حدود ۲۲ مایل) است.

برای جمع‌آوری داده‌ها، دو پرسش‌نامه آماده شد. پرسش‌نامه اول شامل سوالات کلی در مورد دامداری (مانند محل اقامت حیوانات، سوخت‌های مصرفی، تجهیزات مصرف انرژی و غیره) بود. پرسش‌نامه دوم بعد از استخراج نتایج از پرسش‌نامه اول ساخته شد، با در نظر گرفتن پس‌زمینه تحقیق و انتخاب موضوعات مورد علاقه جهت جمع‌آوری اطلاعات دقیق در مورد آن‌ها.

پس از مرور داده‌های جمع‌آوری شده، تصمیم بر آن شد تا تمرکز تحقیق بر روی تجهیزات روشنایی، سیستم خنک‌کننده شیر و دستگاه‌های برقی کنترل دما (گرمایش و سرمایش) برای گاوها و گوساله‌ها قرار گیرد، به عبارت دیگر، بررسی مصرف برق به طور کل. جدول ۱ مشخصات داده‌های ورودی و مشخصات آن‌ها را نشان می‌دهد.

جدول ۱- دستگاه‌های برقی مورد استفاده در پژوهش

نام	واحد	میزان برق مصرفی	تعداد در دامداری
سیستم خنک‌کننده شیر	Wh	1000	1
تأسیسات تابستانی	Wh	1100	6
تأسیسات زمستانی	Wh	250	4
روشنایی	Wh	18	50

در مزرعه مورد مطالعه در این تحقیق، گاوها سه بار در روز شیردهی می‌شوند. هر بار سیستم خنک‌کننده شیر حدود ۳ ساعت در حالت روشن قرار می‌گیرد تا شیر را از دمای حدود ۴۰ درجه سلسیوس در تابستان و حدود ۳۰ درجه سلسیوس در زمستان به دمای ۴ درجه سلسیوس خنک کند.

یکی از موارد دیگری که مورد بررسی قرار گرفت، تجهیزات خنک‌کننده مورد استفاده در تابستان شامل پنکه‌های سقفی و مه‌پاش‌ها بود. دمای محیط ایده‌آل برای گاوها بین ۱۸ تا ۲۵ درجه سلسیوس است. برای حفظ دمای بدن گاوها، هنگامی که هوا گرم می‌شود (معمولاً بالای ۳۰ درجه سلسیوس)، پنکه‌ها و مه‌پاش‌ها به صورت منظم استفاده می‌شوند. پنکه‌ها از ابتدای روزهای گرم روشن می‌شوند و تا غروب آفتاب روشن می‌مانند که دمای هوا کاهش می‌یابد.

در مزارع گاوی، از انواع مختلف لامپ‌های مادون قرمز برای ایجاد هوای گرم و مناسب برای گوساله‌های تازه متولد شده استفاده می‌شود تا از بیماری و استرس سرمایی جلوگیری شود. در مزرعه مورد مطالعه، هنگامی که دمای هوا زیر ۱۰ درجه سلسیوس است، از ۴ لامپ با توان ۲۵۰ وات هرکدام استفاده می‌شود.

آیتم بعدی که در نظر گرفته شده است، روشنایی است. در مجموع، ۵۰ لامپ LED با مصرف ۱۸ وات هرکدام به صورت خودکار از غروب تا روشنایی روز روشن می‌شوند تا نور مناسب برای پرسنل کارگر فراهم کنند. با استفاده از وبسایت timeanddate.com.



دمای هوا برای منطقه مورد نظر (ورامین) از دسامبر ۲۰۲۱ تا دسامبر ۲۰۲۲ وارد شد. به منظور استفاده از داده‌های دقیق، مصرف انرژی به صورت ساعتی تخمین زده شد که شامل یک روز کامل از ساعت ۵ صبح تا ساعت ۴ صبح روز بعد می‌شود. مقدار این انرژی از سازمان برق جمع‌آوری شده است.

جدول ۲- پارامترهای آماری مربوط به ورودی‌ها

کمترین	بیشترین	میانگین	انحراف معیار
دما	-۵	۳۹	۱۷.۴۲۱
سیستم خنک‌کننده شیر	۰	۱	۰.۳۷۵
تأسیسات تابستانی	۰	۱	۰.۱۷۳
تأسیسات زمستانی	۰	۱	۰.۳۵۵
روشنایی	۰	۱	۰.۵۴۹
انرژی	۴.۳	۴۶	۲۱.۰۹۹
زمان	۰	۲۳	۱۱.۵۰۲

جدول ۲ آمارهای اساسی مجموعه داده را نمایش می‌دهد که شامل حداقل، حداکثر، میانگین و انحراف معیار برای تمام متغیرهای مجموعه داده می‌باشد. پس از جمع‌آوری داده‌های تاریخی، مرحله بعدی آموزش شامل نرمال‌سازی اطلاعات بود.

#### پیش‌بینی بر مبنای شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی (ANNs)، همچنین به عنوان شبکه‌های عصبی<sup>۴</sup> (NNs) یا شبکه‌های عصبی شبیه‌سازی شده<sup>۵</sup> (SNNs) نیز شناخته می‌شوند، یک زیرمجموعه از یادگیری ماشین<sup>۶</sup> (ML) هستند و به عنوان یک مؤلفه مرکزی در الگوریتم‌های یادگیری عمیق<sup>۷</sup> عمل می‌کنند. آن‌ها از مغز انسان الهام گرفته‌اند و رفتار ارتباطی نورون‌های زیستی با یکدیگر را مدل می‌کنند (Livingstone, 2008). شبکه‌های عصبی مصنوعی مزایای زیادی دارند از جمله قابلیت مقابله با محدودیت‌های مرتبط با نرم‌افزارهای سنتی. این محدودیت‌ها شامل چالش‌هایی نظیر جمع‌آوری داده‌ها برای اطلاعات محیطی و انرژی، مشکلات فیزیکی پیچیده و محدودیت‌های زبان نرم‌افزار، زمان محاسباتی بیشتر و نیاز به کالیبراسیون مدل می‌شوند. به عبارت دیگر، مدل‌های شبکه عصبی مصنوعی ابزاری تصمیم‌گیری قدرتمند و قابل اعتماد برای مهندسان و معماران ارائه می‌دهند و عدم اطمینان در زمینه ارزیابی

<sup>۴</sup> Neural Networks

<sup>۵</sup> Spiking Neural Networks

<sup>۶</sup> Machine Learning

<sup>۷</sup> Deep Learning



چرخه حیات (LCA) را کاهش می‌دهند. علاوه بر این، یکی از ویژگی‌های مثبت استفاده از شبکه‌های عصبی مصنوعی در نرم‌افزارها، تسهیل ایجاد ابزارهای تصمیم‌گیری موثر است. بنابراین، همانطور که توسط مطالعات مختلف نشان داده شده است، الگوریتم‌ها و تکنیک‌های یادگیری ماشین قابلیت افزایش دقت در ارزیابی چرخه حیات و کاهش زمان شبیه‌سازی را دارند (Sharif and Hammad, 2019; Barros and Ruschel, 2021; D'Amico et al, 2019).

در شبکه عصبی مصنوعی، واحدهای پردازش از نورون‌های لایه‌دار تشکیل شده‌اند که لایه‌های ورودی و خروجی معمولاً توسط یک یا چند لایه مخفی از هم جدا شده‌اند. در هر لایه مخفی، هر نورون ( $i$  به عنوان نورون نشان داده می‌شود) مجموع خروجی‌های وزن‌دار  $x_j$  از نورون‌های لایه قبل را محاسبه کرده و یک بایاس  $b_{ij}$  به این مجموع اضافه می‌کند. سپس این جمع‌ها از طریق یک تابع فعال‌سازی  $\varphi(\cdot)$  عبور داده می‌شوند و به خروجی‌های  $y_i$  منجر می‌شوند. این خروجی‌ها سپس به عنوان ورودی برای نورون‌های لایه بعدی در شبکه عمل می‌کنند. این فرآیند بنیادی برای نحوه پردازش و انتقال اطلاعات توسط لایه‌های پیوندخورده شبکه‌های عصبی مصنوعی است.

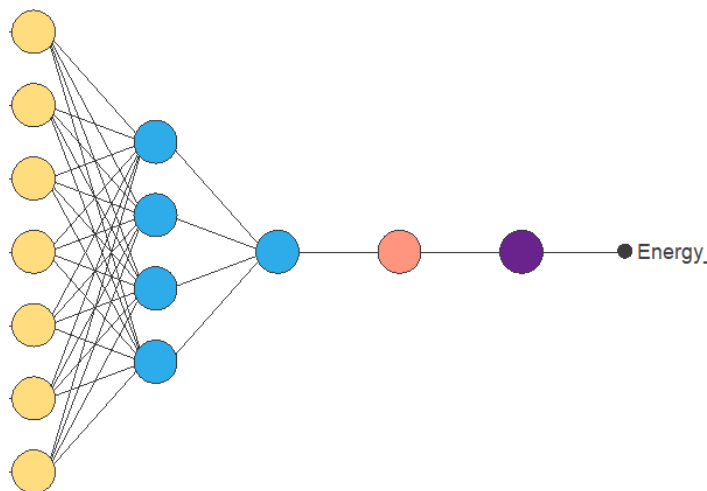
$$y_i = \varphi\left(\sum_{j=1}^N w_{ij}x_j + b_{ij}\right) \quad (1)$$

در اینجا،  $N$  تعداد کل خروجی‌های دریافتی از لایه قبلی را نمایان می‌کند،  $x_j$  خروجی نورون  $j$  از لایه قبل را نشان می‌دهد،  $y_i$  خروجی نورون  $i$  در لایه فعلی است، و  $w_{ij}$  و  $b_{ij}$  به ترتیب به وزن و بایاس اختصاص یافته به ورودی  $j$  برای نورون  $i$  اشاره دارند. علاوه بر این، تابع  $\varphi(\cdot)$  نشان‌دهنده تابع فعال‌سازی استفاده شده است. پارامترهای شبکه عصبی مصنوعی (ANN)، که شامل وزن‌ها ( $w_{ij}$ ) و بایاس‌ها ( $b_{ij}$ ) هستند، از طریق یک فرآیند آموزش نظارت‌شده با استفاده از داده‌های یادگیری تعیین می‌شوند (Ghoroghi et al, 2023; Chu et al, 2015).

شبکه عصبی مصنوعی برای برقراری ارتباط بین متغیرها و عوامل کنترلی و هدف‌های خاص با استفاده از داده‌های تاریخی آموزش داده شد. این فرآیند شامل یک روش آزمون و خطا برای تعیین تعداد ایده‌آل نورون‌های مخفی بود. این فرآیند با یک نورون مخفی در لایه مخفی شروع شد و تعداد نورون‌های مخفی به تدریج افزایش یافت تا به مقدار مطلوب خطای میانگین مربعات رسید<sup>۸</sup> (MSE).

سرانجام، یک ANN ساخته شد که شامل هفت نورون در لایه اولیه، دو لایه مخفی (لایه اول با چهار نورون و دومی با یک نورون) و یک نورون در لایه خروجی بود. در لایه ورودی، متغیرهای زیر دریافت می‌شدند: دمای فعلی، سیستم خنک‌کننده شیر فعلی، تجهیزات فعلی تابستان و زمستان، نورپردازی فعلی، مصرف انرژی فعلی و زمان فعلی که بر اساس ساعت بود. لایه خروجی تخمین مصرف انرژی در آینده را ارائه می‌کرد و پاسخ‌های جمع‌آوری‌شده را سازماندهی می‌کرد (شکل ۱).

<sup>8</sup> Mean squared error



شکل ۱- معماری نهایی شبکه عصبی مصنوعی

برای رفع مشکلات پیچیده با تعداد زیادی ورودی و عدم دانش اولیه برای شناسایی تاخیرهای ممکن، تعداد مناسبی از تاخیرها برای هر متغیر باید تعیین شود. توابع فعال‌سازی مختلف از نظر دقت پیش‌بینی ارزیابی شدند. مدل فعلی از تابع فعال‌سازی تانژانت هیپربولیک به دلیل توانایی کاهش مقادیر افزایی در حالی که حتی پاسخ تقریباً خطی را برای مقادیر میانی حفظ می‌کند، استفاده کرد.

آموزش یک شبکه عصبی شامل بهینه‌سازی وزن‌ها برای ورودی هر واحد است. در این مورد خاص، تعداد کل نمونه‌ها ۹۵۰۰۰ بود که به صورت تصادفی توزیع شدند. تعداد کل نمونه‌ها ۴۹۹۱ نمونه بود. تعداد نمونه‌های آموزش ۲۹۹۴ (۶۰٪)، تعداد نمونه‌های انتخاب ۹۹۸ (۲۰٪) و تعداد نمونه‌های آزمون ۹۹۸ (۲۰٪) بود.

عملکرد مدل با استفاده از معیار خطای میانگین مربعات (MSE) ارزیابی می‌شود، همانطور که در معادله (۲) تعریف شده است. MSE به عنوان معیار استاندارد برای ارزیابی نحوه مطابقت مدل با ارزش‌های پیش‌بینی عمل می‌کند. هدف الگوریتم شبکه عصبی کمینه کردن MSE است که نشان‌دهنده هدف بهبود دقت پیش‌بینی آن است (Ben-Nakhi and Mahmoud, 2002).

$$MSE = \frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (2)$$



$y_n$  نمایانگر مقدار واقعی اندازه‌گیری شده،  $\hat{y}_n$  مقدار تخمین زده شده، و  $N$  متناظر با اندازه نمونه است. برای آموزش، از الگوریتم روش شبه نیوتن<sup>۹</sup> استفاده شد که هنگام برآوردن یک شرط خاص پایان می‌یابد. خسارت آموزش اولیه ۰.۷۹۰۳ بود و پس از ۱۷۶ تکرار، به مقدار نهایی ۰.۱۳۳۸ رسید. به همین ترتیب، خسارت انتخاب اولیه ۱.۷۳۳۴ بود و پس از ۱۷۶ تکرار، به مقدار نهایی ۰.۶۰۸ رسید.

### اجرای الگوریتم ژنتیک

الگوریتم ژنتیک (GA) چندین مزیت را ارائه می‌دهد، از جمله بهینه‌سازی جهانی و نرخ همگرایی سریع. به همین دلیل، می‌توان یک GA را به یک مدل شبکه عصبی چندلایه‌ای<sup>۱۰</sup> (MLP) ادغام کرد تا به طور کارآمد وزن‌های مناسب را تعیین کرده و در نتیجه توانایی پیش‌بینی مدل را بیشینه کند. موفقیت یک GA به اندازه جمعیت بستگی دارد. مانند انتخاب طبیعی، GA بر اساس این اصل عمل می‌کند که افراد با تناسب بالاتر در جمعیت احتمالاً زمانی طولانی‌تر ننگه داشته می‌شوند (Sharma et al, 2022; Tang, 2020; Shirzadi, 2020). در طول این فرآیند، تناسب یک فرد به طور مداوم افزایش می‌یابد و نرم خطا به تدریج کاهش می‌یابد. معکوس نرم خطای MLP به عنوان تابع تناسب برای GA عمل می‌کند و به صورت معادله (۳) محاسبه می‌شود:

$$F = \frac{1}{\frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2} \quad (3)$$

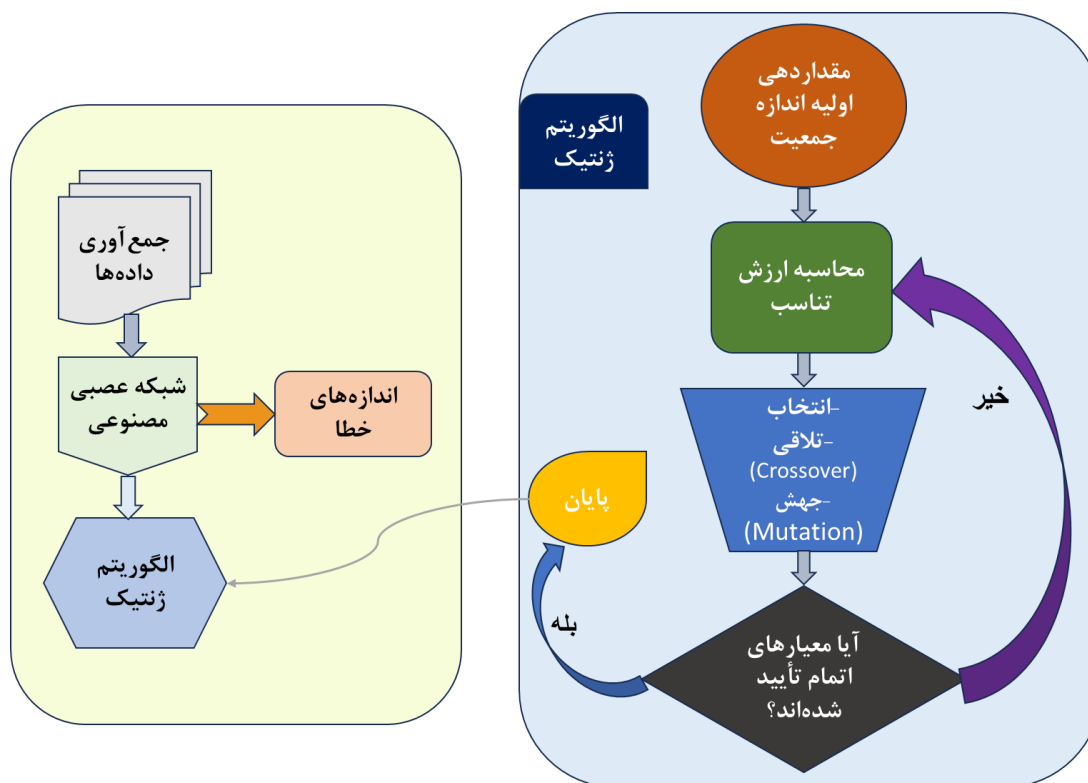
الگوریتم ژنتیک با اولویت دادن به افراد با تناسب بالاتر در جمعیت برتری می‌یابد. بخشی از جمعیت با ارزش‌های تناسب اندام برتر برای نسل بعدی انتخاب می‌شوند. تنوع در میان افراد در جمعیت از طریق تقاطع<sup>۱۱</sup> و جهش<sup>۱۲</sup> معرفی می‌شود و در نتیجه نسل بعدی متمایز ایجاد می‌شود. سپس مشخص می‌شود که آیا نسل‌های کافی تولید شده‌اند یا اینکه معیارهای عملکرد خاصی برای جمعیت برآورده شده‌اند که نشان‌دهنده یک نتیجه رضایت‌بخش است. اگر این شرایط برآورده نشد، تکرارها ادامه می‌یابند، یا تنظیماتی در استراتژی قبل از شروع مجدد فرآیند انجام می‌شود. هنگامی که شرایط پایان بهینه به دست آمد، وزن‌های اولیه برای آن فرآیند ثبت می‌شود و وزن بهینه تعیین می‌شود. شکل ۲ یک نمودار جریان که به بهینه‌سازی یک شبکه عصبی (NN) با استفاده از یک GA می‌پردازد را نشان می‌دهد.

<sup>9</sup> Quasi-Newton

<sup>10</sup> multi-Layer Perceptron

<sup>11</sup> Crossover

<sup>12</sup> Mutation



شکل ۲ نمودار جریان الگوریتم ژنتیک

پارامترهای GA این مطالعه به شرح زیر هستند: اندازه جمعیت ۱۰۰ است که به دلیل کمینه شدن مقادیر خطا در مدل NN انتخاب شده و منجر به عملکرد پیش‌بینی برتر می‌شود. GA از یک جمعیت ۱۰۰ نفره و یک حد تحمل از خسارت انتخاب ۰.۰۱ در دوره آموزش استفاده می‌کند. کروموزوم‌ها به صورت دودویی کدگذاری می‌شوند، به این ترتیب که '۱' ویژگی‌های انتخاب‌شده را نشان می‌دهد و '۰' ویژگی‌های غیرانتخاب‌شده را نشان می‌دهد. الگوریتم از یک روش تلاقی یکنواخت با احتمال ۱ و یک سیستم تخصیص تناسب مبتنی بر رتبه استفاده می‌کند. یک جهش بیتی تغییرات ویژگی‌ها را با وارد کردن بیت‌های جداگانه تغییر می‌دهد و اکتشاف جمعیت را تشویق می‌کند.

### تجزیه و تحلیل ارزیابی چرخه حیات

مدل‌سازی ارزیابی چرخه حیات (LCA) یک تکنیک متداول در تحقیقات اقتصاد کاربردی است. این ابزارهای مدل‌سازی به طور معمول برای ارزیابی تأثیرات زیست‌محیطی یک محصول یا سیستم در طول کل دوره حیات آن، از استخراج مواد اولیه تا دفن، مورد استفاده قرار می‌گیرند. ابزارهای مدل‌سازی LCA یک چارچوب ارائه می‌دهند تا تأثیرات زیست‌محیطی مختلف محصولات یا سیستم‌ها را به صورت کمی و مقایسه‌ای ارزیابی کنند، با در نظر گرفتن معیارهایی نظیر گازهای گلخانه‌ای، مصرف انرژی، هزینه‌های اقتصادی و استنزاف منابع.



نتایج مدل‌سازی LCA نقش حیاتی در فرآیندهای تصمیم‌گیری ایفا می‌کنند، با شناسایی حوزه‌هایی که تأثیرات مهم دارند و فرصت‌های بهبود را مشخص می‌کنند. این ابزارهای مدل‌سازی به طور گسترده در ارزیابی‌های پایداری و تلاش‌های سیاست‌گذاری گنجانده می‌شوند، به منظور کمک به گذار به سمت پایداری بیشتر.

مزرعه مورد تجزیه و تحلیل با استفاده از رویکرد LCA، با پیروی از روش‌های شناخته شده در استانداردهای ISO 14040 و ISO 14044 (I.O., 2016) مورد استفاده قرار گرفته شد. طراحی مطالعه LCA تحت تأثیر بخش‌های قبلی قرار گرفته بود، که شامل استفاده از یادگیری ماشین برای پیش‌بینی سطوح انرژی و الگوریتم ژنتیک برای بهینه‌سازی مصرف انرژی بود. نتایج به دست آمده از مرحله بهینه‌سازی برای ایجاد دو سناریو به کار گرفته شدند که اساس ارزیابی مقایسه‌ای را تشکیل می‌دهند.

در بخش آینده، توضیح مختصری از روش‌شناسی استفاده شده برای انجام ارزیابی چرخه حیات (LCA) ارائه می‌شود.

۱. تعریف هدف و دامنه: این مرحله شامل مشخص کردن اهداف، واحد کارکردی و مرزهای سیستمی برآورد است. هدف از این مرحله اساساً تعریف شاخص‌های زیست‌محیطی برای نگهداری گاو و تولید شیر و شناسایی مؤثرترین شاخص‌ها در آلاینده‌های زیست‌محیطی است. این مطالعه در نظر دارد تا درک مدیران را از تأثیرات زیست‌محیطی مرتبط با استراتژی‌های مصرف برق افزایش دهد. علاوه بر این، هدف آن ارائه بینشی در مورد شیوه‌های مؤثر برای بهره‌برداری و مدیریت منابع انرژی است.

۲. تجزیه و تحلیل موجودی چرخه عمر<sup>۱۳</sup> (LCI): در این مرحله داده‌های مربوط به ورودی‌ها و خروجی‌ها برای تمامی فرآیندهای درون سیستم جمع‌آوری می‌شود. LCI برای این مطالعه با ترکیب منابع داده اولیه و ثانویه ایجاد شد. داده‌های اولیه از شبیه‌سازی‌های انرژی و بهینه‌سازی انجام شده در بخش‌های قبلی برای هر دو سناریو پایه و بهینه‌سازی شده به دست آمد. این داده‌های اولیه به طور خاص به مصرف انرژی برق امکانات زمستانی، و روشنایی در دامداری مربوط می‌شوند. داده‌های مربوط به این دو فرآیند واحد مرتبط با تولید برق از پایگاه داده Ecoinvent 3.8 استخراج شد.

۳. ارزیابی تأثیر چرخه حیات<sup>۱۴</sup> (LCIA): در اینجا، اثرات زیست‌محیطی فرآیندها ارزیابی می‌شود. بسیار مهم است که تأکید شود انتخاب روش ارزیابی تأثیر و دسته‌بندی تأثیر به اهداف و دامنه مطالعه بستگی دارد. این انتخاب‌ها ممکن است بر اساس سیستم محصول خاص تحت ارزیابی متفاوت باشد. در چارچوب این مطالعه، هدف انجام مقایسه عملکرد محیطی بین سناریوی پایه و سناریوی بهینه شده برای مصرف برق است. روش ReCiPe Midpoint به دلیل پوشش آن از تمام مقوله‌های تأثیر مرتبط به عنوان روش ارزیابی تأثیر در این مطالعه انتخاب شد.

۴. تفسیر چرخه زندگی: این مرحله شامل تفسیر نتایج و نتیجه‌گیری بر اساس ارزیابی است.

این اصول و چارچوب، راهنمای تجزیه و تحلیل چرخه حیات (LCA) مزارع هستند.

<sup>13</sup> Life Cycle Inventory

<sup>14</sup> Life Cycle Impact Assessment



ابزارهای مختلفی برای انجام مطالعات ارزیابی چرخه زندگی (LCA) در دسترس هستند، از جمله نرم افزارهای جایگزین منبع باز و اختصاصی. در مطالعه حاضر، Brightway2، یک نرم افزار منبع باز نوشته شده در پایتون، برای ساخت مدل LCA مورد استفاده قرار گرفت. Brightway2 دو حالت کار را ارائه می دهد: می توان از آن در یک نوت بوک Jupyter یا از طریق مرورگر Activity استفاده کرد، که یک رابط کاربری گرافیکی است که از Brightway2 در پس زمینه استفاده می کند. Brightway2 کاربران را به طیف وسیعی از قابلیت‌ها مجهز می کند و آنها را قادر می سازد تا مجموعه داده‌های گسترده را مدیریت کنند، مدل‌های پیچیده ایجاد کنند و با پایگاه‌های داده متنوع تعامل داشته باشند.

### مدل ریاضی

مدل پیش‌بینی به شکل یک تابع از خروجی‌ها در مورد ورودی‌ها است. می‌توانید عبارت ریاضی که توسط این مدل نماینده شده است را به صورت محاسباتی در نرم‌افزار دیگر در حالت تولید (production mode) جاسازی کنید. فهرست زیر حاوی عبارت ریاضی است که توسط شبکه عصبی نشان داده شده است. این عبارت ورودی‌های:

Temp-lag	دمای قبلی
Milk Cooling System-lag	دستگاه خنک کننده شیر قبلی
Summer Facilities-lag	تأسیسات تابستانی قبلی
Winter Facilities-lag	تأسیسات زمستانی قبلی
Lighting Set Point-lag	روشنایی قبلی
Energy-lag	انرژی قبلی
Hour-lag	زمان (برحسب ساعت) قبلی

را گرفته و خروجی انرژی پیش رو یا Energy\_ahead را تولید می‌کند.

در مدل‌های پیش‌بینی، شبکه عصبی اطلاعات را از طریق لایه‌های مقیاس، پرسپترون و بی مقیاس به صورت فیدفوروارد (feed-) forward منتقل می‌کند.

$$st = 0.097281.(Temp\_lag) - 1.69471$$

$$smcs = 2.(Milk\ Cooling\ System\_lag) - 1$$

$$ssf = 2.(Summer\ Facilities\_lag) - 1$$

$$swf = 2.(Winter\ Facilities\_lag) - 1$$

$$sls = 2.(Lighting\ Set\ point\_lag) - 1$$

$$sel = 0.0947724.(Energy\_lag) - 1.99956$$



$$shl = 0.144465 \cdot (Hour\_lag) - 1.66157$$

$$p_1o_0 = \tanh(0.493164 \cdot sel - 0.651794 \cdot shl + 0.64563 \cdot sls - 0.0402832 \cdot smcs - 0.299438 \cdot ssf + 0.169983 \cdot st + 0.79187 \cdot swf - 0.997498)$$

$$p_1o_1 = -\tanh(0.8172 \cdot sel + 0.271118 \cdot shl + 0.970032 \cdot sls - 0.420959 \cdot smcs - 0.0270386 \cdot ssf - 0.717834 \cdot st + 0.392029 \cdot swf - 0.127136)$$

$$p_1o_2 = -\tanh(0.990662 \cdot sel + 0.982178 \cdot shl + 0.761841 \cdot sls + 0.668213 \cdot smcs - 0.97699 \cdot ssf + 0.705383 \cdot st + 0.108643 \cdot swf + 0.613403)$$

$$p_1o_3 = \tanh(-0.667542 \cdot sel + 0.32605 \cdot shl + 0.214294 \cdot sls + 0.0632935 \cdot smcs + 0.142334 \cdot ssf - 0.244263 \cdot st + 0.203491 \cdot swf + 0.617432)$$

$$p_2o_0 = -0.295776 \cdot p_1o_0 - 0.885925 \cdot p_1o_1 + 0.215332 \cdot p_1o_2 + 0.566589 \cdot p_1o_3 - 0.0984497$$

$$ulo_0 = -3.12011 \cdot p_1o_0 - 9.34553 \cdot p_1o_1 + 2.27152 \cdot p_1o_2 + 5.97689 \cdot p_1o_3 + 20.0639$$

نگاشت نام متغیرهای کوتا‌تر به نام اصلی آنها:

st: scaled Temp\_lag

مقیاس اندازه دما در زمان یکساعت قبل

smcs: scaled Milk Cooling System\_lag

مقیاس اندازه دستگاه خنک‌کننده شیر در زمان یکساعت قبل

ssf: scaled Summer Facilities\_lag

مقیاس اندازه تأسیسات تابستانی در زمان یکساعت قبل

swf: scaled Winter Facilities\_lag

مقیاس اندازه تأسیسات زمستانی در زمان یکساعت قبل

sls: scaled Lighting Set point\_lag

مقیاس اندازه روشنایی در زمان یکساعت قبل

sel: scaled Energy\_lag

مقیاس اندازه انرژی مصرفی در زمان یکساعت قبل

shl: scaled Hour\_lag

مقیاس اندازه زمان در زمان یکساعت قبل

$p_1o_0$ : perceptron layer1\_output0

لایه‌ی اول پرسپترون - خروجی صفر

$p_1o_1$ : perceptron layer1\_output1

لایه‌ی اول پرسپترون - خروجی یک

$p_1o_2$ : perceptron layer1\_output2

لایه‌ی اول پرسپترون - خروجی دو

$p_1o_3$ : perceptron layer1\_output3

لایه‌ی اول پرسپترون - خروجی سه

$p_2o_0$ : perceptron layer2\_output0

لایه‌ی دوم پرسپترون - خروجی صفر

$ulo_0$ : unscaling layer\_output0

لایه‌ی بدون مقیاس - خروجی صفر



همانطور که در معماری نهایی (شکل ۱) مشاهده می‌شود، این مدل از دو لایه از پرسپترون تشکیل شده است (لایه اول شامل ۷ ورودی و لایه دوم شامل ۴ خروجی)، همراه با یک لایه بدون مقیاس که متناظر با خروجی (پیش‌بینی انرژی) است.

پس از استخراج مدل ریاضی در برنامه Python، به بهینه‌سازی آن پرداخته شد. متغیرهایی که ممکن بودند تغییر کنند، در جهت کاهش مصرف انرژی خود انتخاب شدند و این متغیرها در الگوریتم ژنتیک بهینه‌سازی شدند. دو متغیر انتخاب شده مربوط به امکانات گرمایشی در زمستان و روشنایی بودند. سپس، محدودیت‌های این دو متغیر بررسی خواهند شد.

### ارزیابی مدل

برای ارزیابی عملکرد مدل، از چندین پارامتر آماری استفاده کردیم که شامل خطای میانگین مربعات (MSE)، ریشه خطای میانگین مربعات (RMSE)<sup>۱۵</sup> و خطای مجموع مربعات (SSE) می‌شود. MSE میانگین مربعات اختلاف بین مقادیر واقعی مشاهده شده و مقادیر پیش‌بینی شده توسط مدل را اندازه‌گیری می‌کند. RMSE یک قانون امتیازدهی درجه دوم است که میانگین بزرگی خطاها را نیز ارزیابی می‌کند. به طور مشابه، SSE اختلاف مجذور کل بین مقادیر واقعی مشاهده شده و مقادیر پیش‌بینی شده تولید شده توسط یک مدل رگرسیونی را کمی می‌کند. فرمول‌های MSE، RMSE و SSE به ترتیب در معادلات (۲)، (۴) و (۵) آورده شده‌اند.

$$RMSE = \sqrt{MSE} \quad (4)$$

$$SSE = \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (5)$$

جدول ۱ یک نمای کلی جامع از تمام خطاهای اندازه‌گیری شده در مرحله آزمایش ارائه می‌دهد.

جدول ۳ انواع خطا در مرحله تست

تست	نوع خطا	
442.453	مجموع مجذور خطا	SSE
0.443	خطای میانگین مربعات	MSE
0.666	ریشه میانگین مربعات خطا	RMSE

<sup>15</sup> Root mean squared error

<sup>16</sup> Sum squared error



## بهینه سازی مدل

برای کاهش مصرف انرژی، از یک الگوریتم ژنتیک برای برخی از متغیرهای ورودی مسئله مورد بررسی استفاده شد. ابتدا، متغیرهایی که ممکن بودند در فرآیند عملیاتی فعلی دامداری برای بهینه‌سازی و کاهش مصرف انرژی تغییر کنند، انتخاب شدند. این متغیرها که قبلاً ذکر شد، شامل روشنایی و تأسیسات زمستانی هستند. الگوریتم ژنتیک با استفاده از کتابخانه pymoo پیاده‌سازی شد.

الگوریتم ژنتیک برای استخراج یک استراتژی عملیاتی بهینه برای ۲۴ ساعت آینده به کار گرفته شد. پارامترهای الگوریتم ژنتیک از جمله اندازه جمعیت، انتخاب، جهش و عملگرهای چرخش بهینه‌سازی شدند تا بهترین نتایج به دست آید. GA یک روش بهینه‌سازی قدرتمند است که قادر به یافتن راه‌حل‌های رضایت‌بخش است، حتی زمانی که مسئله در معرض عدم قطعیت است یا زمانی که فضای راه‌حل گسترده است. در تحقیق مورد بررسی، چندین محدودیت و عدم قطعیت وجود دارد که بدون در نظر گرفتن آن‌ها در فرآیند بهینه‌سازی، راه‌حل نامطلوب و ناکارآمد می‌شد. با گنجاندن این عدم قطعیت‌ها در فرآیند بهینه‌سازی الگوریتم ژنتیک، راه‌حلی می‌توان به دست آورد که در برابر تغییرات ورودی‌ها قوی باشد.

این محدودیت‌ها عبارتند از:

محدودیت ۱:

متغیر روشنایی  $x_5$  تحت یک محدودیت قرار دارد به گونه‌ای که هنگامی که روز روشن می‌شود، لامپ‌ها خاموش یا صفر تنظیم می‌شوند و هنگام شروع تاریکی (در غروب آفتاب)، لامپ‌ها روشن یا به ۱ تنظیم می‌شوند. در محدودیت زیر،  $x_7$  نمایانگر زمان است.

$$x_5 = \begin{cases} 1 & \text{if } (x_7 < \text{sunset}) \text{ or } (x_7 \geq \text{dawn}) \\ 0 & \text{if } (\text{sunset} \leq x_7 < \text{dawn}) \end{cases} \quad (6)$$

لامپ‌ها  
زمان

محدودیت ۲:

این محدودیت بیان می‌کند که وقتی دما  $x_1$  زیر ۱۰ درجه سانتی‌گراد باشد، تسهیلات زمستانی  $x_4$  روشن می‌شود و به صورت ۱ نشان داده می‌شود. برعکس، وقتی دما ۱۰ درجه سانتی‌گراد یا بالاتر است، تأسیسات زمستانی خاموش می‌شود و به صورت صفر نشان داده می‌شود.

$$x_4 = \begin{cases} 1 & \text{if } x_1 < 10 \\ 0 & \text{if } x_1 \geq 10 \end{cases} \quad (7)$$

دما  
تسهیلات زمستانی



با معرفی محدودیت ها و استفاده از کد پایتون استخراج شده از طریق ANN، الگوریتم ژنتیک در محیط پایتون اجرا شد. الگوریتم ژنتیک انرژی را به طور قابل توجهی کاهش داد و آن را از مقدار کل ۱۰۵۳۰۴۰۷ کیلووات به ۷۰۳۳۲۰۰۶ کیلووات رساند. حال با در دسترس بودن انرژی و انرژی بهینه، در قسمت بعدی به تخمین شاخص های زیست محیطی LCA می پردازیم.

### تجزیه و تحلیل LCA

برای محاسبه LCA به کمک پایگاه داده اکواینونت و با استفاده از نرم افزار برای وی در پایتون، انتشارات زیست محیطی انرژی کل اولیه و انرژی بهینه شده به دست آورده و سپس مقایسه گردید. با توجه به آنکه کشور ایران در پایگاه اکواینونت تعریف نگردیده، کشور امارات مدنظر قرار گرفت.

با توجه به وجود تعداد زیاد فاکتورهای شیمیایی، چند مورد آنها انتخاب گردید و در جدول ۴ نشان داده شد.

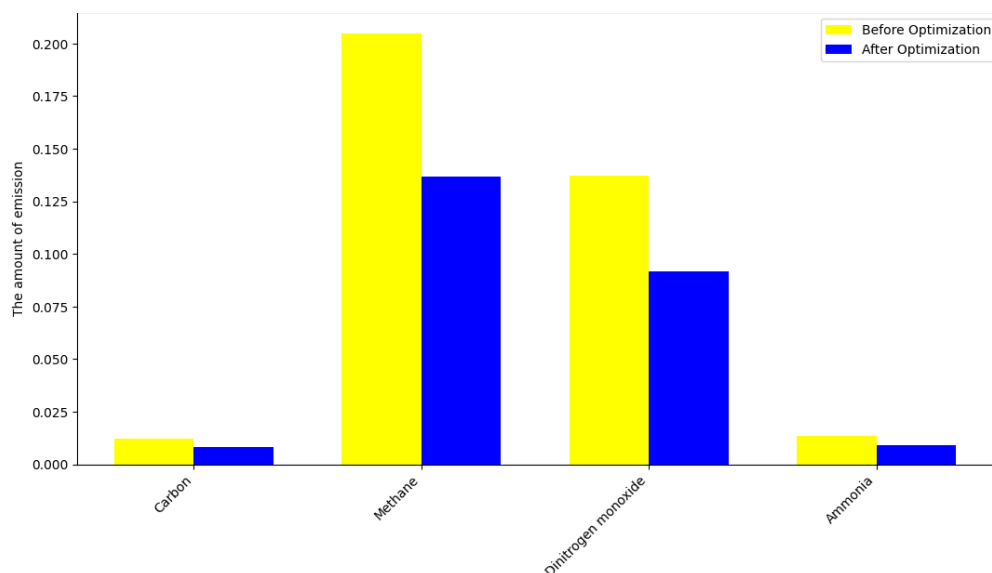
جدول ۴- مقدار انتشارات زیست محیطی

نام	نام انگلیسی	واحد	مقدار وزن پیش از بهینه سازی	مقدار وزن پیش از بهینه سازی
کربن	Carbon	kg	۰۰۰۸۰۶۵۸۲۷۰۲۶۳۰۷۹۱	۰۰۱۲۰۵۴۱۹۵۸۰۵۶۲۲۲
کربن دی اکسید، فسیل	Carbon dioxide, fossil	kg	۱۶۴۰۰۷۶۴۳۷۴۱۸۱۴۴	۲۴۵۲۰۰۸۵۱۹۵۰۷۸۳۳
کربن دی اکسید، غیر فسیلی	Carbon dioxide, non-fossil	kg	۱۹۰۸۴۸۹۷۷۶۲۶۰۸۸۹	۲۹۰۶۶۳۸۴۷۴۹۷۰۸۸۱
کربن دی اکسید، در هوا	Carbon dioxide, in air	kg	۷۸۰۲۰۵۲۳۴۳۱۵۵۶۶۵	۱۱۶۰۸۷۵۹۵۱۳۹۲۱۶۹
متان، فسیل	Methane, fossil	kg	۰۰۱۳۶۹۴۶۷۴۳۴۴۳۰۰۲	۰۰۲۰۴۶۶۳۸۰۶۳۳۰۰۸۶
متان، غیر فسیلی	Methane, non-fossil	kg	۰۰۰۱۸۱۲۳۶۸۲۷۰۷۷۶۶۹	۰۰۰۲۷۰۸۵۴۳۳۳۱۸۳۴۷۹



۵.۳۴۱۹۲۱۶۱۳۶۴۱۱۷	۷.۹۸۳۳۸۰۸۶۱	kg	Nitrogen oxides	نیتروژن اکسید
۸.۰۲۳۶۴۹۷۸۹۸۴۶۶۷E-۰۹	۱.۱۹۹۱۱۶۲۸۸۱۰۱۵E-۰۸	kg	Ozone	اُزن
۸.۸۰۰۷۳۵۳۹۳۳۱۲۷۹	۱۳.۱۵۲۴۹۹۷۱۴۹۶۳۸	kg	Sulfur dioxide	دی‌اکسید گوگرد

با مقایسه‌ی دو جدول مقدار کاهش یافته‌ی تمام آلاینده‌ها قابل مشاهده می‌باشد. با توجه به این دو جدول مقدار کربن از مقدار ۰.۰۱۲۰۵۴۱۹۵۸۰۵۶ کیلوگرم به مقدار ۰.۰۰۸۰۶۵۸۲۷۰۲۶ رسیده است. مقدار نیتروژن اکسید و دی اکسید گوگرد نیز به ترتیب ۷.۹۸۳۳۸۰۸۶۱ و ۱۳.۱۵۲۴۹۹۷۱ کیلوگرم در پیش از بهینه سازی بوده است که پس از آن به مقدارهای ۵.۳۴۱۹۲۱۶ و ۸.۸۰۰۷۳۵۳۹ رسیده اند. بنابراین کاهش ۳۳ درصدی این شاخص‌ها نتیجه‌ی بهینه سازی یکساله مدل مورد استفاده بوده است.



شکل ۳ - مقایسه برخی انتشارات زیست محیطی قبل و بعد از بهینه سازی

همانطور که در شکل ۳ مشاهده می‌کنید، مقدار کربن، متان، دی نیتروژن مونوکسید و آمونیاک که شاخص های مضر در آلودگی زیست محیطی می‌باشند، پیش از بهینه سازی به رنگ زرد و پس از اعمال بهینه سازی به رنگ آبی در نمودار می‌باشند. مقادیر این انتشارات به طور قابل ملاحظه‌ای با اعمال تغییر در روند مصرف تنها دو مورد از وسایل برقی مورد استفاده در دامداری، کاهش پیدا کرده است.



## نتیجه‌گیری

در این تحقیق روند مصرف انرژی برق در دامداری های شهرستان ورامین بررسی شد. این مطالعه به منظور کمک به محیط زیست از طریق کاهش مصرف انرژی برق در زنجیره تامین دامداری هدف انجام شد. با توجه به زمان‌بر بودن جمع‌آوری و تحلیل داده‌ها در کل زنجیره تامین و در دسترس نبودن داده‌ها برای تمام مراحل زنجیره تامین دام، یک مرحله تولید مورد بررسی قرار گرفت. این امر با طراحی پرسشنامه ای برای مدیران دامداری مورد نظر جهت کسب اطلاعات لازم جهت تدوین مدل مصرف انرژی انجام شد. با توجه به داده‌های موجود و استفاده از ANN در یادگیری ماشین، داده‌ها مدل‌سازی گشتند. کد ریاضی به دست آمده توسط مدل می تواند برای جاسازی آن در نرم افزارهای دیگر استفاده شود. مقادیر کم خطای به دست آمده در شبکه عصبی مصنوعی نشان دهنده قابلیت این تکنیک در توسعه یک مدل مصرف انرژی است. این رویکرد کاوش و کاربرد داده می تواند در سایر صنایع نیز قابل اجرا باشد. با کمک مدل به دست آمده، دو عامل ورودی با استفاده از الگوریتم ژنتیک در نرم افزار پایتون بهینه سازی شدند که در نتیجه، بهبود ۳۳٪ مشاهده شد.

بنابراین با کاهش و بهینه سازی مصرف انرژی برق، تمامی آلاینده های زیست محیطی مرتبط با آن نیز کاهش یافت. این مطالعه تأثیر مثبت آن بر محیط زیست نشان داده است. استفاده از یادگیری ماشین (ML) در این تحقیق دقت مدل LCA را افزایش می‌دهد و بینش‌های ارزشمندی را برای تصمیم‌گیرندگان علاقه‌مند به توسعه شیوه‌های سازگار با محیط زیست فراهم می‌کند. این تحقیق پتانسیل تکنیک‌های ML و بهینه‌سازی را برای کاهش اثرات زیست‌محیطی دامداری با بهبود کارایی انرژی آنها برجسته می‌کند.



## منابع

- Robinson, T., Thornton, P., Franceschini, G., Kruska, R., Chiozza, F., Noten-baert, A., Cecchi, G., Herrero, M., Epprecht, M., Fritz, S., et al.: Global Livestock Production Systems, FAO and ILRI, Rome (2011)
- Gilbert, M., Nicolas, G., Cinardi, G., Van Boeckel, T.P., Vanwambeke, S.O., Wint, G., Robinson, T.P.: Global distribution data for cattle, buffaloes, horses, sheep, goats, pigs, chickens and ducks in 2010. *Scientific data* 5(1), 1–11 (2018)
- Finnegan, W., Yan, M., Holden, N.M., Goggins, J.: A review of environmental life cycle assessment studies examining cheese production. *The International Journal of Life Cycle Assessment* 23, 1773–1787 (2018)
- Food, United Nations (FAO), A.O.: Greenhouse gas emissions from the dairy sector: a life cycle assessment. FAO Rome, Italy (2010)
- Guzm'an-Luna, P., Mauricio-Iglesias, M., Flysj"o, A., Hospido, A.: Analysing the interaction between the dairy sector and climate change from a life cycle perspective: A review. *Trends in Food Science & Technology* 126, 168–179 (2022)
- GDP, F.: In climate change and the global dairy cattle sector—the role of the dairy sector in a low-carbon future. The Food and Agriculture Organization: Rome, Italy (2018)
- Wang, F., Harindintwali, J.D., Wei, K., Shan, Y., Mi, Z., Costello, M.J., Grun-wald, S., Feng, Z., Wang, F., Guo, Y., et al.: Climate change: Strategies for mitigation and adaptation. *The Innovation Geoscience* 1(1), 100015–61 (2023)
- Rotz, C.A., Montes, F., Chianese, D.S.: The carbon footprint of dairy production systems through partial life cycle assessment. *Journal of Dairy Science* 93(3), 1266–1282 (2010) <https://doi.org/10.3168/jds.2009-2162>
- Todde, G., Murgia, L., Caria, M., Pazzona, A.: A comprehensive energy analysis and related carbon footprint of dairy farms, part 2: Investigation and modeling of indirect energy requirements. *Energies* 11(2), 463 (2018)
- Ilyas, H.M.A., Safa, M., Bailey, A., Rauf, S., Pangborn, M.: The carbon footprint of energy consumption in pastoral and barn dairy farming systems: A case study from canterbury, new zealand. *Sustainability* 11(17), 4809 (2019)
- Khaleghy, H., Wahid, A., Clifford, E., Mason, K.: Modelling electricity con-sumption in irish dairy farms using agent-based modelling. *arXiv preprint arXiv:2308.09488* (2023)
- Ilyas, H.M.A., Safa, M., Bailey, A., Rauf, S., Khan, A.: Energy efficiency out-look of new zealand dairy farming systems: An application of data envelopment analysis (dea) approach. *Energies* 13(1), 251 (2020)
- Sharafi, S., Kazemi, A., Amiri, Z.: Estimating energy consumption and ghg emissions in crop production: A machine learning approach. *Journal of Cleaner Production* 408, 137242 (2023) <https://doi.org/10.1016/j.jclepro.2023.137242>
- Sefeedpari, P., Rafiee, S., Akram, A., Komleh, S.H.P.: Modeling output energy based on fossil fuels and electricity energy consumption on dairy farms of iran: Application of adaptive neural-fuzzy inference system technique. *Computers and electronics in agriculture* 109, 80–85 (2014)
- Sefeedpari, P., Rafiee, S., Akram, A.: Application of artificial neural network to model the energy output of dairy farms in iran. *International journal of energy technology and policy* 9(1), 82–91 (2013)

- Shine, P., Scully, T., Upton, J., Murphy, M.: Annual electricity consumption prediction and future expansion analysis on dairy farms using a support vector machine. *Applied energy* 250, 1110–1119 (2019)
- Shine, P., Murphy, M.D., Upton, J., Scully, T.: Machine-learning algorithms for predicting on-farm direct water and electricity consumption on pasture based dairy farms. *Computers and electronics in agriculture* 150, 74–87 (2018)
- Ghoroghi, A., Petri, I., Rezgui, Y., Alzahrani, A.: A deep learning approach to pre-dict and optimise energy in fish processing industries. *Renewable and Sustainable Energy Reviews* 186, 113653 (2023)
- Howell, S.K., Wicaksono, H., Yuce, B., McGlinn, K., Rezgui, Y.: User centered neuro-fuzzy energy management through semantic-based optimization. *IEEE transactions on cybernetics* 49(9), 3278–3292 (2018)
- Ferdyn-Grygierek, J., Grygierek, K.: Multi-variable optimization of building thermal design using genetic algorithms. *Energies* 10(10), 1570 (2017)
- Yuce, B., Rezgui, Y.: An ann-ga semantic rule-based system to reduce the gap between predicted and actual energy consumption in buildings. *IEEE Transactions on Automation Science and Engineering* 14(3), 1351–1363 (2015)
- Reynolds, J., Ahmad, M.W., Rezgui, Y., Hippolyte, J.-L.: Operational supply and demand optimisation of a multi-vector district energy system using artificial neural networks and a genetic algorithm. *Applied energy* 235, 699–713 (2019)
- Sharma, D.K., Hota, H., Brown, K., Handa, R.: Integration of genetic algorithm with artificial neural network for stock market forecasting. *International Journal of System Assurance Engineering and Management* 13(Suppl 2), 828–841 (2022)
- Livingstone, D.J.: *Artificial Neural Networks: Methods and Applications*. Springer, ??? (2008)
- Sharif, S.A., Hammad, A.: Developing surrogate ann for selecting near-optimal building energy renovation methods considering energy consumption, lcc and lca. *Journal of Building Engineering* 25, 100790 (2019)
- Barros, N.N., Ruschel, R.C.: Machine learning for whole-building life cycle assess-ment: A systematic literature review. In: *Proceedings of the 18th International Conference on Computing in Civil and Building Engineering: ICCCBE 2020*, pp. 109–122 (2021). Springer
- D’Amico, A., Ciulla, G., Traverso, M., Brano, V.L., Palumbo, E.: Artificial neural networks to assess energy and environmental performance of buildings: An italian case study. *Journal of Cleaner Production* 239, 117993 (2019)
- Chu, Y., Pedro, H.T., Li, M., Coimbra, C.F.: Real-time forecasting of solar irradiance ramps with smart image processing. *Solar Energy* 114, 91–104 (2015)
- Ben-Nakhi, A.E., Mahmoud, M.A.: Energy conservation in buildings through efficient a/c control using neural networks. *Applied Energy* 73(1), 5–23 (2002)
- Tang, S.-Z., Li, M.-J., Wang, F.-L., He, Y.-L., Tao, W.-Q.: Fouling potential prediction and multi-objective optimization of a flue gas heat exchanger using neural networks and genetic algorithms. *International Journal of Heat and Mass Transfer* 152, 119488 (2020)
- Shirzadi, A., Asadi, S., Shahabi, H., Ronoud, S., Clague, J.J., Khosravi, K., Pham, B.T., Ahmad, B.B., Bui, D.T.: A novel ensemble learning based on bayesian belief network coupled with an extreme learning machine for flash flood susceptibility mapping. *Engineering Applications of Artificial Intelligence* 96, 103971 (2020)
- Standardization, I.O.: *Environmental Management: Life Cycle Assessment; Prin-ciples and Framework* vol. 14040



## Improving energy efficiency with an LCA approach: A case study in livestock farming

Asal Seyedagha

Ali Ghoroghi

Alireza Momajed

### Abstract

Given the considerable impact of livestock care on global warming and environmental pollution, we examined and improved the life cycle of maintaining cattle and calves, along with the production of dairy products in a farm situated in Varamin, Iran. This study employed an Artificial Neural Network (ANN) model, initially trained on simulation data, and subsequently utilized by the Genetic Algorithm (GA) as a fitness evaluation function to find the optimal solution. This optimization strategy resulted in noteworthy energy savings, approximately 32% compared to the baseline scenario. The findings from these models were then incorporated into the Life Cycle Assessment (LCA) model to evaluate the environmental impacts and energy efficiency related to electricity usage for winter facilities and lighting on the farm. This enhances the precision of the LCA model and provides valuable tools for decision-makers aiming to implement more eco-friendly practices. Moreover, the study underscores the potential of Machine Learning (ML) and optimization techniques in mitigating the environmental impacts of livestock electricity consumption by improving energy efficiency.

**Keywords:** Machine Learning, Artificial Neural Network, Life Cycle Assessment, Genetic Algorithm, Livestock