

## روشی نوین جهت بهبود مصرف انرژی در شهر هوشمند با استفاده یادگیری عمیق

آزاده منصوری

موسسه آموزش عالی غیر انتفاعی لامعی گرگانی  
[azadehemansouri@gmail.com](mailto:azadehemansouri@gmail.com)

رضا روشنی

1. موسسه آموزش عالی غیر انتفاعی لامعی گرگانی  
2. گروه مهندسی کامپیوتر، دانشگاه ملی مهارت، تهران، ایران  
[r.roshany@gmail.com](mailto:r.roshany@gmail.com)

### چکیده:

امروزه با توجه به افزایش تقاضای انرژی، مدیریت بهینه مصرف انرژی به یکی از چالش‌های اصلی در شهرهای هوشمند تبدیل شده است. این تحقیق گامی مهم در جهت هوشمند سازی مدیریت انرژی در شهرهای هوشمند است. در این تحقیق برای پیش‌بینی دقیق مصرف انرژی یک مدل ترکیبی مبتنی بر یادگیری عمیق، شبکه‌های عصبی کانولوشنی<sup>۱</sup> (CNN) و شبکه عصبی حافظه‌های طولانی کوتاه مدت<sup>۲</sup> (LSTM) پیشنهاد می‌شود. با ترکیب این دو مدل، می‌توان پیش‌بینی دقیق‌تری از مصرف انرژی آینده داشت و با شناسایی الگوهای پیچیده مصرف انرژی و ارائه راهکارهای بهینه سازی مصرف انرژی تصمیمات بهتری برای مدیریت انرژی اتخاذ کرد. ابتدا داده‌های مصرف انرژی از منابع مختلف مانند حسگرها و کنتورهای هوشمند جمع‌آوری می‌شود سپس پیش‌پردازش داده‌ها برای آماده سازی آنها برای آموزش مدل انجام می‌شود و از CNN برای استخراج ویژگی‌های مکانی از داده‌های مصرف انرژی و LSTM برای درک الگوهای زمانی این داده‌ها و پیش‌بینی مصرف انرژی استفاده می‌شود. روش پیشنهادی دارای مزایایی نظیر دقت بالای پیش‌بینی مصرف انرژی، شناسایی الگوهای پیچیده در مصرف انرژی، امکان اتخاذ تصمیمات بهتر برای مدیریت انرژی، کمک به کاهش مصرف انرژی و بهبود پایداری محیط زیست است.

**کلمات کلیدی:** شهر هوشمند، یادگیری عمیق، شبکه‌های عصبی کانولوشنی، شبکه عصبی حافظه‌های طولانی کوتاه مدت، پیش‌بینی مصرف انرژی، بهینه‌سازی انرژی

1 Convolutional Neural Networks (CNN)

2 Long Short-Term Memory (LSTM)

## 1. مقدمه

با رشد سریع شهرها و افزایش تقاضا برای انرژی، مدیریت بهینه مصرف انرژی به یکی از چالش‌های اصلی در شهرهای هوشمند تبدیل شده است. اینترنت اشیاء به شبکه‌ای از اشیاء فیزیکی گفته می‌شود که به اینترنت متصل هستند و می‌توانند با یکدیگر و با محیط اطراف خود تعامل داشته باشند [1-2-3]. این فناوری در حوزه‌های مختلفی مانند شهرسازی (پارکینگ هوشمند، مدیریت ترافیک، روشنایی هوشمند)، محیط زیست (تشخیص آتش سوزی، آلودگی هوا) و کشاورزی (خانه‌های هوشمند، شبکه ایستگاه هواشناسی) کاربرد دارد. با وجود مزایای فراوان، اینترنت اشیاء با چالش‌هایی مانند حجم بالای داده‌ها، امنیت داده‌ها، یکپارچه‌سازی سیستم‌ها و استاندارد سازی مواجه است. ساختمان‌ها یکی از بزرگترین مصرف‌کنندگان انرژی هستند. الگوریتم‌های یادگیری ماشین می‌توانند در بهینه‌سازی مصرف انرژی ساختمان‌ها از طریق پیش‌بینی تقاضای انرژی، بهینه‌سازی عملکرد سیستم‌های HVAC<sup>۱</sup>، تشخیص خرابی تجهیزات، مدیریت روشنایی و مدیریت مصرف آب نقش مهمی ایفا کنند. مزایای استفاده از الگوریتم‌های یادگیری ماشین در ساختمان‌های هوشمند می‌تواند به کاهش مصرف انرژی، افزایش آسایش ساکنان، کاهش هزینه‌ها، افزایش عمر مفید تجهیزات و پایداری بیشتر اشاره کرد. از چالش‌های استفاده از الگوریتم‌های یادگیری ماشین در ساختمان‌های هوشمند می‌توان به نیاز به داده‌های با کیفیت، پیچیدگی پیاده‌سازی، هزینه و مسائل امنیتی اشاره کرد [4-5-6].

از کاربردهای اینترنت اشیاء و یادگیری ماشین در شهرهای هوشمند می‌توان به استفاده از اینترنت اشیاء برای جمع‌آوری داده‌های حجیم از محیط شهری، استفاده از یادگیری ماشین برای تحلیل داده‌ها و استخراج اطلاعات برای تصمیم‌گیری، استفاده از فناوری‌های هوشمند برای بهبود کیفیت زندگی شهروندان و افزایش کارایی خدمات شهری اشاره کرد [8].

در این میان، روش‌های ماشین بردار پشتیبان<sup>۲</sup> (SVM) و الگوی  $k$  نزدیکترین همسایه<sup>۳</sup> (KNN) به عنوان دو روش پرکاربرد و موثر محسوب می‌شوند. SVM با هدف یافتن بهترین مرز تصمیم‌گیری بین داده‌ها عمل می‌کند و از مفاهیمی مانند فضای ویژگی، توابع هسته و حاشیه حداکثری بهره می‌برد. این الگوریتم به دلیل تعمیم‌پذیری بالا و کارایی در داده‌های با ابعاد بالا، در بسیاری از مسائل طبقه‌بندی و رگرسیون مورد استفاده قرار می‌گیرد. روشی ساده‌تر است که بر اساس نزدیکی نمونه‌های جدید به نمونه‌های آموزشی عمل می‌کند. KNN برای طبقه‌بندی و رگرسیون قابل استفاده است و به دلیل سادگی پیاده‌سازی، محبوبیت زیادی دارد. انتخاب بین SVM و KNN به عوامل مختلفی مانند حجم داده‌ها، پیچیدگی مسئله، و منابع محاسباتی بستگی دارد. SVM برای مسائل پیچیده و داده‌های با ابعاد بالا مناسب‌تر است، در حالی که KNN برای مسائل ساده‌تر و داده‌های کوچک‌تر انتخاب بهتری است [10]. مدیریت بهینه مصرف انرژی در شهرهای هوشمند دارای اهمیت است چراکه با پیش‌بینی دقیق مصرف انرژی، می‌توان برنامه‌ریزی بهتری برای تولید و توزیع انرژی انجام داد و از هدررفت انرژی جلوگیری کرد، با بهینه‌سازی مصرف انرژی هزینه‌های مربوط به مصرف انرژی را کاهش داد، همچنین منجر به کاهش انتشار گازهای گلخانه‌ای و بهبود محیط زیست می‌شود.

روش پیشنهادی مبتنی بر CNN-LSTM توانایی مدل در یادگیری الگوهای فضایی و زمانی، توانایی بالایی در شناسایی الگوهای پیچیده و پیش‌بینی دقیق مصرف انرژی را دارد.

1 Heating, Ventilation, and Air

2 Support Vector Machine

3 k-Nearest Neighbors

## 2. کارهای مرتبط

این مطالعات (پژوهش‌های پیشین) به دنبال راه‌هایی برای بهبود مدیریت انرژی ساختمان‌ها و شهرهای هوشمنداند. مقاله Marinakis یک سیستم پیشرفته مبتنی بر اینترنت اشیا (IOT1) را برای مدیریت هوشمند انرژی در ساختمان‌ها ارائه کرد. درواقع، یک چارچوب معنایی با هدف مدل‌سازی یکپارچه و استاندارد شده موجودیت‌هایی که محیط ساختمان را تشکیل می‌دهند، معرفی شد. قوانین مناسبی با هدف مدیریت هوشمند انرژی و روش کلی ساختمان هوشمند شکل گرفت. در این زمینه، یک سیستم مبتنی بر اینترنت اشیا پیاده‌سازی شد که تعامل سیستم‌های مدیریت انرژی ساختمان‌ها را افزایش می‌داد. نتایج حاصل از کاربرد آزمایشی آن ارائه و مورد بحث قرار گرفت. سیستم پیشنهادی رویکردهای موجود را گسترش داد و داده‌های بین دامنه‌ای مانند داده‌های ساختمان (به عنوان مثال، سیستم‌های مدیریت انرژی)، تولید انرژی، قیمت انرژی، داده‌های آب و هوا و رفتار کاربران نهایی را به منظور تولید برنامه‌های اقدام روزانه و هفتگی را یکپارچه کرد [7].

در روشی دیگر توسط Simonofski، هدف، شناسایی عوامل زمینه‌ای است که بر استراتژی‌های مشارکت شهروندان در شهرهای هوشمند تأثیر می‌گذارد. برای رسیدن به این هدف، یک مطالعه موردی کیفی از دو شهر انجام شد که در تلاش برای هوشمند بودن هستند: نامور (بلژیک) و لینکوپینگ (سوئد). این تجزیه و تحلیل این امکان را می‌دهد که عوامل زمینه‌ای را که بر استراتژی‌های مربوطه تأثیر می‌گذارند. پنج عامل زمینه‌ای در این مطالعه شناسایی شده‌اند: توجه به شهر هوشمند، محرک‌های مشارکت، میزان تمرکز، الزامات قانونی و ویژگی‌های شهروندان. با شناسایی این عوامل، می‌توان توصیه‌های وابسته به زمینه را در مورد مشارکت شهروندان برای شهرهای هوشمند استخراج کرد. این توصیه‌ها سپس در مورد بروکسل در بلژیک اعمال شدند [9].

Zeki و همکاران، مدل‌های مجموعه‌ای را برای پیش‌بینی سری‌های زمانی کلان داده ارائه می‌کرد. مجموعه‌ای متشکل از سه روش (درخت تصمیم، درختان با گرادبان تقویت شده و جنگل تصادفی) با توجه به نتایج خوبی که این روش‌ها در کاربردهای کلان داده قبلی به دست آورده‌اند، پیشنهاد شد. وزن مجموعه با روش حداقل مربعات وزنی محاسبه شد. دو استراتژی مربوط به به روز رسانی وزن در نظر گرفته شده است که منجر به یک مدل مجموعه ایستا یا پویا شد. پیش‌بینی‌های هر یک از اعضای گروه با تقسیم مسئله پیش‌بینی به  $h$  به دست آمد. با توجه به موارد ذکر شده، تحقیق جامعی در خصوص تجزیه و تحلیل داده‌های حجیم و پیش‌بینی مصرف انرژی به کمک الگوریتم‌های یادگیری ماشین با دقت بالا و بهبود صحت کافی صورت نگرفته است. [10].

A.Ullahetal و همکاران، به بررسی مفهوم شهرهای هوشمند و نقش اینترنت اشیا (IoT) و یادگیری ماشین (یادگیری ماشین) در تحقق یک محیط هوشمند مبتنی بر داده می‌پردازد. شهرهای هوشمند از فناوری و داده برای بهبود کیفیت زندگی شهروندان و ارتقای کارآمدی خدمات شهری استفاده می‌کنند. اینترنت اشیا و یادگیری ماشین به عنوان فناوری‌های کلیدی برای ایجاد راه‌حل‌های شهر هوشمند که بر جمع‌آوری داده‌های حجیم، تجزیه و تحلیل و تصمیم‌گیری تکیه دارند، ظهور کرده‌اند. این مقاله با ارائه مروری بر کاربردهای مختلف شهرهای هوشمند، چالش‌های مرتبط با پیاده‌سازی اینترنت اشیا و یادگیری ماشین در محیط‌های شهری را مورد بحث قرار می‌دهد. همچنین، این مقاله به مقایسه مطالعات موردی مختلف از اجرای موفق شهرهای هوشمند با استفاده از فناوری‌های اینترنت اشیا و یادگیری ماشین می‌پردازد. یافته‌ها نشان می‌دهند که این فناوری‌ها پتانسیل متحول کردن محیط‌های شهری و امکان ایجاد شهرهایی با قابلیت سکونت بیشتر، پایدارتر و کارآمدتر را دارند. با این وجود، چالش‌های قابل توجهی در رابطه با حفظ حریم خصوصی داده‌ها، امنیت و ملاحظات اخلاقی وجود دارد که برای تحقق کامل پتانسیل شهرهای هوشمند باید به آن‌ها پرداخته شود. [16]

<sup>1</sup> Internet of Things

ردیف	عنوان	سال	مزایا	معایب	مجموعه داده‌ها	معیارهای ارزیابی
1 Marinakis	یک سیستم پیشرفته مبتنی بر اینترنت اشیا برای مدیریت هوشمند انرژی در ساختمان‌ها ارائه کرد	2018	بهبود کارایی انرژی و کاهش مصرف انرژی در ساختمان‌ها افزایش اطلاعات و کنترل بر مصرف انرژی به صورت هوشمند و اتوماتیک	محدودیت‌های مرتبط با پیاده‌سازی و اجرای سیستم‌های پیچیده مدیریت انرژی نیاز به هزینه‌های بالا برای اجرای و نگهداری سیستم‌ها پیچیدگی‌های مرتبط با انطباق و تطبیق سیستم با نیازهای مختلف ساختمان‌ها	داده‌های مدیریت انرژی هوشمند در ساختمان‌ها اطلاعات مربوط به مصرف انرژی، سیستم‌های IoT، و اطلاعات محیطی مورد استفاده در سیستم	مصرف انرژی، کارایی، کاهش هزینه‌های انرژی، افزایش سطح راحتی در ساختمان
2 Simono fski	بررسی عوامل زمینه‌ای در استراتژی‌های مشارکت شهروندان: تحلیل مقایسه‌ای شهرهای هوشمند سوئد و بلژیک.	2019	ارائه الگوها و رویکردهای موفق در توسعه شهرهای هوشمند افزایش درک از مزایای و چالش‌های متمایز شهرهای هوشمند این دو کشور	محدودیت‌های مربوط به دسترسی به داده‌ها و اطلاعات مقایسه‌پذیر پیچیدگی‌های مرتبط با تفسیر نتایج مقایسه بین دو کشور و نیاز به توجه به تفاوت‌های فرهنگی و سیاسی در ارزیابی شهرهای هوشمند	داده‌های مرتبط با شهرهای هوشمند در سوئد و بلژیک اطلاعات مربوط به فناوری‌ها، خدمات، و شاخص‌های عملکرد شهرهای هوشمند مورد مقایسه	میزان پیشرفت فناوری در شهرهای مورد مقایسه سطح خدمات الکترونیکی و هوشمند در شهرها تأثیر استفاده از فناوری بر بهبود کیفیت زندگی شهروندان اندازه‌گیری سطح مشارکت شهروندی در فرایندها و تصمیم‌گیری‌های شهری
3 Zeki	یادگیری عمیق در مدل سازی هزینه‌های انرژی ساختمان‌ها در بخش دولتی	2019	افزایش دقت و پیش‌بینی بهتر هزینه‌های انرژی با استفاده از الگوریتم‌های یادگیری عمیق	نیاز به حجم بالای داده و محاسبات پیچیده برای پیاده‌سازی یادگیری عمیق مدل‌های یادگیری عمیق ممکن است پیچیدگی زیادی داشته باشند که نیازمند توانایی محاسباتی بالا برای آموزش و استفاده از آن‌ها باشد.	اطلاعات انرژی مصرفی ساختمان‌های بخش دولتی، مشخصات ساختمان، شاخص‌های انرژی و داده‌های محیطی مرتبط با ساختمان‌های دولتی	معیارهای خطا، دقت، حساسیت و ویژگی‌های دیگر برای ارزیابی کارایی مدل‌های یادگیری عمیق در پیش‌بینی هزینه‌های انرژی
4 A.ullah et al	شهرهای هوشمند: نقش اینترنت اشیا و یادگیری ماشینی در تحقق یک محیط هوشمند داده محور	2023	افزایش کیفیت زندگی شهروندان از طریق بهره‌برداری از اینترنت اشیا و یادگیری ماشین در محیط‌های هوشمند. افزایش کارایی در ارائه خدمات شهری و بهبود مدیریت شهری از طریق این فناوری‌ها.	حفاظت از حریم خصوصی نیاز به سرمایه‌گذاری بزرگ و هزینه‌های بالا برای پیاده‌سازی این فناوری‌ها در شهرها.	اطلاعات مربوط به محیط شهری (مانند داده‌های انرژی، ترافیک، آلودگی هوا و ...) و داده‌های حاصل از سیستم‌های اینترنت اشیا	دقت و کیفیت داده‌های حاصل از سنسورها و دستگاه‌های هوشمند عملکرد مدل‌های یادگیری ماشین در پیش‌بینی و مدیریت داده‌های حاصل از این فناوری‌ها. تأثیر استفاده از این فناوری‌ها بر کیفیت زندگی شهروندان و بهبود مدیریت شهری

جدول 1: خلاصه‌ای از روش‌های پیشین [7-9-10-16]

### 3. روش پیشنهادی

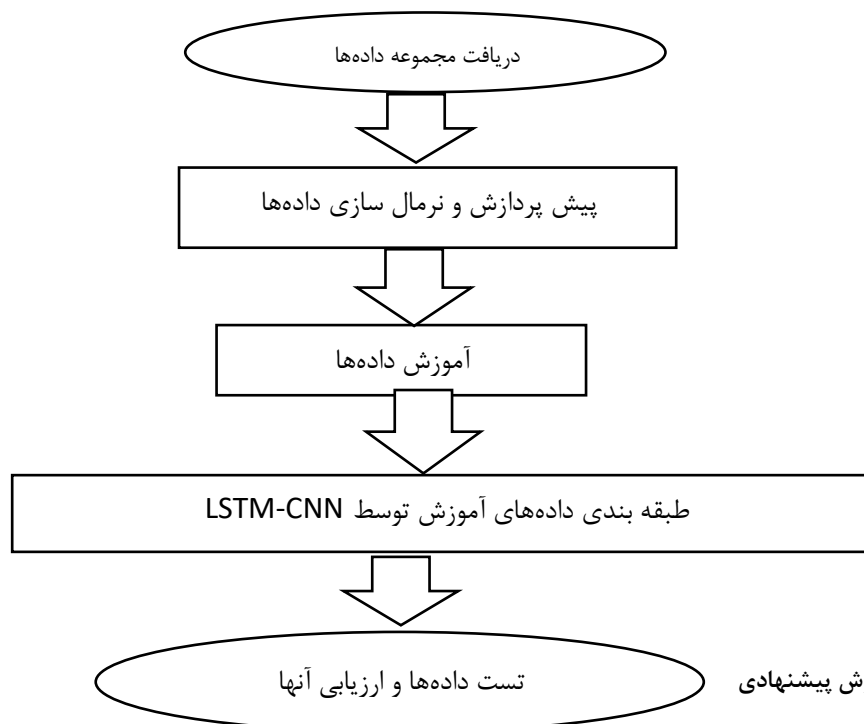
روش پیشنهادی با استفاده از ترکیب روش‌های یادگیری عمیق LSTM و CNN است که در چهار بخش، جمع‌آوری داده‌ها، پیش‌پردازش، آموزش مدل و تست مدل می‌باشد که در ادامه به هر یک از آن‌ها می‌پردازیم. (شکل کلی از روند روش پیشنهادی در شکل 1 نشان داده شده است)

الف- جمع‌آوری داده‌های مصرف انرژی از منابع مختلف مانند سنسورها و سیستم‌های هوشمند.  
 ب- پیش‌پردازش داده‌ها با حذف نویز، تکمیل داده‌های گم شده و نرمال‌سازی داده‌ها باعث می‌شود مدل بتواند الگوهای نهفته در داده‌ها را بهتر شناسایی کند. پیش‌پردازش داده‌ها نقش بسیار مهمی در بهبود عملکرد مدل دارد.  
 ج- آموزش مدل LSTM-CNN: تقسیم داده‌ها به مجموعه‌های آموزشی، اعتبارسنجی و آزمون و تنظیم هایپرپارامترهای مدل (مانند نرخ یادگیری، تعداد لایه‌ها، و تعداد دوره‌های آموزشی) و استفاده از الگوریتم‌های بهینه‌سازی (مانند آدام (Adam)<sup>۷</sup> یا گرادیان نزولی تصادفی (SGD)<sup>۸</sup> و انتخاب معیارهای ارزیابی مانند خطای میانگین مربعات (MSE)<sup>۹</sup>، دقت، و میانگین مطلق خطا (MAE)<sup>۱۰</sup> برای ارزیابی عملکرد مدل مذکور استفاده می‌شوند، این معیارها به مدل اجازه می‌دهند که خطاهای پیش‌بینی در مقایسه با مقادیر واقعی را در حین آموزش کاهش دهد.

در فرایند آموزش مدل‌های یادگیری عمیق، داده‌ها به سه دسته تقسیم می‌شوند:

- داده‌های آموزشی: بزرگترین بخش، 70-80٪ از داده‌ها که برای آموزش اولیه مدل استفاده می‌شود. مدل با استفاده از این داده‌ها الگوها و روابط بین ورودی‌ها و خروجی‌ها را یاد می‌گیرد.
- داده‌ها اعتبارسنجی: حدود 10-20٪ از داده‌ها برای ارزیابی مدل در طول فرآیند جلوگیری از بیش‌برازش می‌باشد.
- داده‌های آزمون: داده‌های باقی‌مانده (حدود 10٪) برای ارزیابی نهایی عملکرد مدل پس از اتمام آموزش استفاده می‌شوند.

د- پیش‌بینی مصرف انرژی: استفاده از مدل آموزش دیده برای پیش‌بینی مصرف انرژی در آینده.



7 Adam Optimization Algorithm (Adam)

8 Stochastic Gradient Descent (SGD)

9 Mean squared error (MSE)

10 Mean Absolute Error (MAE)

### 1.3. نحوه عملکرد مدل:

**الف-** استخراج ویژگی‌های فضایی توسط CNN: لایه‌های CNN با استفاده از فیلترها، الگوهای محلی و ویژگی‌های مهم را از داده‌های ورودی استخراج می‌کنند.

**ب -** یادگیری وابستگی‌های زمانی توسط LSTM: خروجی لایه‌های CNN به لایه‌های LSTM داده می‌شود. LSTM با استفاده از سلول‌های حافظه و دروازه‌ها، وابستگی‌های زمانی و الگوهای بلندمدت را در داده‌ها یاد می‌گیرد.

**ج -** پیش‌بینی مصرف انرژی: مدل آموزش دیده با استفاده از اطلاعات استخراج شده از CNN و LSTM، مقدار مصرف انرژی آینده را پیش‌بینی می‌کند.

### 2.3. مزایای روش پیشنهادی:

- دقت بالا: مدل CNN-LSTM می‌تواند الگوهای پیچیده و تکراری در داده‌های مصرف انرژی را به طور دقیق ترشناسایی و پیش‌بینی کند.
- انعطاف‌پذیری: مدل می‌تواند با انواع مختلف داده‌های مصرف انرژی کار کند.
- قابلیت تعمیم‌پذیری: مدل می‌تواند به راحتی به داده‌های جدید و شرایط مختلف تعمیم داده شود.

### 4. یافته‌ها

روش پیشنهادی یکی از مدل‌های یادگیری عمیق با ترکیب CNN-LSTM است. داده‌های مورد استفاده در این پژوهش مربوط به مصرف انرژی در آلمان در سال 2019 هستند که به صورت مکانی در سطح NUTS2<sup>11</sup> (شامل 38 منطقه) آلمان تقسیم‌بندی شده‌اند که این امکان را می‌دهد تا مصرف انرژی را در مناطق مختلف کشور مقایسه کرد و به صورت زمانی در ساعت‌ها تفکیک شده‌اند، تا نوسانات مصرف انرژی به دقت نشان دهند. داده‌ها به چهار کاربرد مختلف تفکیک شده‌اند: بخش‌های مسکونی، صنعتی، تجاری و حمل‌ونقل. همچنین الگوهای مصرف در هفت حوزه مختلف مورد بررسی قرار گرفته‌اند: گرمایش فضا، آب گرم، گرمایش فرآیندی، سرمایش فضا، سرمایش فرآیندی، انرژی مکانیکی، فناوری اطلاعات و ارتباطات، و روشنایی.

در آموزش مدل‌های یادگیری عمیق جهت ارزیابی مدل‌ها از معیارهایی مانند MSE و دقت و MAE استفاده می‌گردد. میانگین خطای مطلق یا MAE از قدرمطلق خطاهای مدل میانگین گرفته می‌شود. ابتدا از خطاها قدر مطلق می‌گیریم، چرا که نمی‌خواهیم مقادیر مثبت و منفی باعث خنثی شدن یک‌دیگر شوند. پس از محاسبه قدرمطلق مقادیر باقیمانده، آن‌ها را با هم جمع و نتیجه را بر تعداد کل نمونه‌ها تقسیم می‌کنیم. مقدار بدست آمده نشان‌دهنده میزان خطای پیش‌بینی تا مقدار واقعی است. در این روش تفاوتی میان خطاهای بزرگ و کوچک وجود ندارد. عمده کاربرد میانگین خطای مطلق در سنجش دقت پیش‌بینی‌ها است. فرمول محاسبه MAE به شرح زیر است:

$$MAE = 1/n \sum_{i=1}^n |x_i - \hat{x}|$$

• N برابر است با تعداد کل نمونه‌ها.

•  $x_i$  برابر است با مقادیر پیش‌بینی شده.

• X برابر است با مقادیر حقیقی.

**معیار خطای میانگین مربعات (MSE)** با میانگین گرفتن از تفاضل مقادیر حقیقی و پیش‌بینی شده، میزان خطای مدل‌های آماری را اندازه می‌گیرد و خطاهای بزرگ‌تر تشدید می‌گردد. از این معیار زمانی استفاده می‌گردد که وجود خطاهای بزرگ مطلوب نیست.

$$MSE = 1/n \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$


(طبقه‌بندی واحدهای سرزمینی، برای تقسیمات کشوری، کشورها، برای مقاصد آماری است. فقط شامل کشورهای عضو اتحادیه اروپا می‌شود)<sup>11</sup>

- $N$  برابر است با تعداد کل نمونه‌ها.
- $\hat{y}_i$  برابر است با مقادیر پیش‌بینی شده.
- $y_i$  برابر است با مقادیر حقیقی.

سپس الگوریتم‌هایی برای بهینه‌سازی مصرف انرژی بر اساس نتایج پیش‌بینی پیاده‌سازی می‌شوند و خروجی‌های حاصل شده به صورت نمودار و جدول ارائه شده و عملکرد مدل‌های مختلف مقایسه می‌شود.


#### 1.4 میزان مصرف انرژی در بازه زمانی مختلف

تحلیل الگوهای مصرف انرژی برای شناسایی رفتار مصرف و پیشنهاد راهکارهای بهینه‌سازی ضروری است. نمودارهای مصرف انرژی می‌تواند به تفکیک بازه‌های زمانی مختلف، نوسانات مصرف را نمایش دهد و نقاط اوج و کمینه مصرف را مشخص کند. شکل 2 میزان مصرف انرژی را در چهار بخش مختلف (تجاری، صنعتی، حمل و نقل و مسکونی) در طول یک روز نشان می‌دهد. هر رنگ در نمودار نشان‌دهنده یک بخش خاص است (تجاری با رنگ بنفش، صنعتی با رنگ زرد، حمل و نقل با رنگ سبز و مسکونی با رنگ آبی) و ارتفاع هر خط نشان‌دهنده میزان مصرف انرژی در آن ساعت است. مصرف انرژی را در چهار بخش مختلف در طول یک روز را نشان می‌دهد.




شکل 2- مصرف انرژی طی یک روز [21]

شکل 3، میزان مصرف انرژی را در چهار بخش مختلف (تجاری، صنعتی، حمل و نقل و مسکونی) در طول یک هفته نشان می‌دهد. هر رنگ در نمودار نشان‌دهنده یک بخش خاص است (تجاری با رنگ بنفش، صنعتی با رنگ زرد، حمل و نقل با رنگ سبز و مسکونی با رنگ آبی) و ارتفاع هر خط نشان‌دهنده میزان مصرف انرژی در آن روز است. مصرف انرژی را در چهار بخش مختلف در طول یک هفته را نشان می‌دهد.



شکل 3- مصرف انرژی طی یک هفته نشان می‌دهد. [21]

شکل 4 میزان مصرف انرژی را در چهار بخش مختلف (تجاری، صنعتی، حمل و نقل و مسکونی) طی یک سال نشان می‌دهد. هر رنگ در نمودار نشان‌دهنده یک بخش خاص است (تجاری با رنگ بنفش، صنعتی با رنگ زرد، حمل و نقل با رنگ سبز و مسکونی با رنگ آبی) و ارتفاع هر ستون نشان‌دهنده میزان مصرف انرژی در آن ماه است.




شکل 4- مصرف انرژی را در طی یک سال نشان می‌دهد. [21]

برخی از نتایج حاصل از نمودارها: بیشترین سهم مصرف انرژی در بخش تجاری و مسکونی مربوط به سیستم‌های سرمایشی و گرمایشی است که وابسته به نوسانات شدید فصلی است. مصرف انرژی در بخش تجاری یک الگوی مشخص و قابل پیش‌بینی دارد که می‌تواند به عوامل مختلفی مانند شرایط آب و هوایی، نوع فعالیت‌های تجاری و سیاست‌های انرژی مرتبط باشد، که با شناسایی این الگوها می‌توان اقدامات لازم برای بهینه‌سازی مصرف انرژی در زمان‌های مختلف سال و در بخش‌های مختلف ساختمان‌های تجاری را انجام داد.

## 2.4. ارزیابی روش پیشنهادی LSTM+CNN

در این بخش با استفاده از مدل ترکیبی LSTM+CNN که برای پیش‌بینی مصرف انرژی مورد استفاده قرار گرفته، داده‌ها به دو بخش آموزش (80 درصد) و تست (20 درصد) تقسیم شده‌اند. مدل‌ها با استفاده از داده‌های تست ارزیابی می‌شوند. شکل 5: نشان‌دهنده مقایسه‌ای بین مقادیر واقعی با رنگ مشکی و مقادیر پیش‌بینی شده توسط مدل با رنگ‌های متفاوت است. در اینجا معیار ارزیابی، میانگین مربعات خطا MSE می‌باشد. تا عملکرد مدل در پیش‌بینی الگوهای مصرف انرژی بررسی شود.

The root mean squared error is 6.29.



شکل 5. بررسی مدل ترکیبی LSTM+CNN برای پیش‌بینی مصرف انرژی (ارزیابی با معیار، میانگین مربعات خطا MSE)




- **مشاهدات:** در بسیاری از قسمت‌های نمودار، مدل پیش‌بینی مقادیر بسیار نزدیک به مقادیر واقعی انجام داده است. این امر نشان‌دهنده عملکرد مطلوب مدل در پیش‌بینی مصرف انرژی است.
- **نقاط اختلاف:** در بعضی نقاط اختلاف بین مقادیر واقعی و پیش‌بینی شده وجود دارد. این نوسانات به علت پیچیدگی الگوهای مصرف و وابستگی‌های زمانی غیرخطی در داده‌ها ممکن است رخ داده باشد. با این حال، این اختلافات چشم‌گیر نیست و عملکرد کلی مدل قابل قبول به نظر می‌رسد.

به طور کلی، مدل ترکیبی LSTM+CNN توازن مناسبی بین پیش‌بینی مناسب از مصرف انرژی، برسد و با توجه به نزدیکی نتایج پیش‌بینی شده به مقادیر واقعی، می‌توان نتیجه گرفت که این مدل پتانسیل بالایی برای بهینه‌سازی مصرف انرژی دارد.

### 3.4. ارزیابی معیار MAE روش پیشنهادی با سایر روش‌ها

در شکل 6: روش پیشنهادی با سایر روش‌های موجود LSTM، CNN، RNN+<sup>12</sup>CNN با معیار میانگین مطلق خطا مورد مقایسه قرار می‌گیرد.



شکل 6-مقایسه روش پیشنهادی با سایر روش‌ها (ارزیابی با معیار میانگین مطلق خطا)

در این نمودار میله‌ای میانگین خطای مطلق برای چهار مدل مختلف محاسبه شده و به شرح زیر است:

1. LSTM دارای MAE برابر با 11.8 است که بیشترین مقدار خطا در این نمودار است.
2. CNN مقدار MAE برابر با 9.2 است، که نسبت به LSTM خطای کمتری دارد.
3. LSTM + RNN مقدار MAE برابر با 7.2 است و از دو مدل قبلی بهتر عمل کرده است.
4. روش پیشنهادی: مقدار MAE برابر با 6.29 است که کمترین مقدار خطا را نشان می‌دهد.

این تحلیل نشان می‌دهد که روش پیشنهادی بهترین عملکرد را در کاهش میانگین مطلق خطا دارد و کمترین خطای پیش‌بینی را داشته است و مدل LSTM بیشترین خطا را به همراه دارد.

## 5. نتیجه گیری

این پژوهش به دنبال یافتن راهکارهایی برای بهبود مصرف انرژی در شهرهای هوشمند با استفاده از تکنیک‌های یادگیری عمیق بوده است. داده‌های مصرف انرژی از منابع مختلف جمع‌آوری شده و پس از پاک‌سازی و آماده‌سازی برای آموزش مدل استفاده شده است. برای مدل‌سازی مصرف انرژی، از ترکیبی از شبکه‌های عصبی کانولوشنی (CNN) و (LSTM) برای تحلیل وابستگی‌های زمانی استفاده شده است. مدل با استفاده از داده‌های آموزشی آموزش دیده و سپس با داده‌های تست ارزیابی شده است. نتایج آزمایش‌ها نشان داد که مدل ترکیبی CNN-LSTM توانسته است عملکرد مناسبی داشته باشد و معیارهایی مانند میانگین مطلق خطا (MAE) مقادیر قابل قبولی را ارائه دادند. مقایسه مقادیر واقعی و پیش‌بینی شده نشان داد که در بسیاری از بازه‌های زمانی، مدل توانسته به درستی مقادیر مصرف انرژی را تخمین بزند. با وجود برخی اختلافات جزئی در برخی نقاط، عملکرد کلی مدل در پیش‌بینی مصرف انرژی بسیار مطلوب بوده است. مدل ترکیبی CNN-LSTM توانسته است با دقت بالایی الگوهای مصرف انرژی را پیش‌بینی کند، به خصوص در بخش تجاری. بنابراین تکنیک‌های یادگیری عمیق به ویژه مدل‌های ترکیبی CNN-LSTM ابزار قدرتمندی برای تحلیل و پیش‌بینی مصرف انرژی هستند. با استفاده از این مدل‌ها می‌توان بهینه‌سازی مصرف انرژی را در سطح کلان انجام داد، هزینه‌ها را کاهش داد و سبب بهبود کارایی انرژی شود. در نتیجه بهبود مصرف انرژی به کاهش انتشار گازهای گلخانه‌ای و حفاظت از محیط زیست کمک می‌کند و موجب پایداری محیط زیست می‌گردد. برای ادامه کار پیشنهاد می‌گردد از این مدل برای پیش‌بینی مصرف انرژی در بخش‌های خانگی و صنعتی و گسترش مدل به سایر بخش‌ها استفاده گردد. هم‌چنین ترکیب مدل‌های یادگیری عمیق با سایر روش‌های بهینه‌سازی برای افزایش کارایی نیز پیشنهاد می‌گردد.

## منابع:

- [1]. Calvillo, C. F., Sanchez-Mirallas, A., & Villar, J. (2016). Energy management and planning in smart cities. *Renewable and Sustainable Energy Reviews*, 55, 273–287. <https://doi.org/10.1016/j.rser.2015.10.133>.
- [2]. Cocchia, A. (2014). Smart and digital city: A systematic literature review. In R. Dameri, & C. Rosenthal-Sabroux (Eds.), *Smart city. How to create public and economic value with high technology in urban space. progress in IS* (pp. 13–43). Cham: Springer. [https://doi.org/10.1007/978-3-319-06160-3\\_2](https://doi.org/10.1007/978-3-319-06160-3_2).
- [3]. Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda. *International Journal of Information Management*, 48, 63–71. <https://doi.org/10.1016/j.ijinfomgt.2019.01.021>
- [4]. Rasmussen, M. H., Pauwels, P., Hviid, C. A., & Karlshoj, J. (2017). Proposing a central AEC ontology that allows for domain specific extensions. In *Proceedings of the joint conference on computing in construction (JC3)* (pp. 237–244). <https://doi.org/10.24928/JC3-2017/0153>. Vol. 1.
- [5]. Schneider, G. F., & Rasmussen, M. H. (2018). Technical building systems/open smart home data: First release of open smart home data set (Version v1.0.0). Zenodo. <https://doi.org/10.5281/zenodo.1244602>.
- [6]. Scitovski, R., Zekić-Sušac, M., & Has, A. (2018). Searching for an optimal partition of incomplete data with application in modeling energy efficiency of public buildings. *Croatian Operationa*
- [7]. Marinakis, V., & Doukas, H. (2018). An advanced IoT-based system for intelligent energy management in buildings. *Sensors*, 18(2), 610. <https://doi.org/10.3390/s18020610>, 1-16.

- [8]. Lopez-Robles, J. R., Otegi-Olaso, J. R., Porto Gomez, I., & Cobo, M. J. (2019). 30 years of intelligence models in management and business: A bibliometric review. *International Journal of Information Management*, 48, 22–38. <https://doi.org/10.1016/j.ijinfomgt.2019.01.013>.
- [9]. Simonofski, A., Vallée, T., Serral, E., & Wautelet, Y. (2019). Investigating context factors in citizen participation strategies: A comparative analysis of Swedish and Belgian smart cities. *International Journal of Information Management*, Article 102011. <https://doi.org/10.1016/j.ijinfomgt.2019.09.007>. In Press. Corrected Proof. Available online 3 October 2019.
- [10]. Zekić-Sušac, M., Knežević, M., & Scitovski, R. (2019). Deep learning in modeling energy cost of buildings in the public sector. In F. Martinez Alvarez, A. Tronosco Lora, J. Sáez Muñoz, H. Quintián, & E. Corchado (Eds.), *Advances in intelligent systems and computing*, 950 pp. 101–110. Cham, Switzerland: Springer. <https://doi.org/10.1007/978-3-030-20055-8>, 2019.
- [11]. K. Pourjavan, Explanation of smart city and smart transportation solutions, *Karafan* 16 (2019), no. 1, 15–35.
- [12]. C.F. Calvillo, A. Sánchez-Miralles and J. Villar, Energy management and planning in smart cities, *Renew. Sustain. Energy Rev.* 55 (2016), 273–280.
- [13]. N.P. Rana, S. Luthra, S.K. Mangla, R. Islam, S. Roderick and Y.K. Dwivedi, Barriers to the development of smart cities in Indian context, *Inf. Syst. Front.* 21 (2019), 503–525.
- [14]. S. Tanwar, A. Popat, P. Bhattacharya, R. Gupta and N. Kumar, A taxonomy of energy optimization techniques for smart cities: Architecture and future directions, *Expert Syst.* 39 (2022).
- [15]. X. Zhang, G. Manogaran and B. Muthu, IoT enabled integrated system for green energy into smart cities, *Sustain, Energy Technol. Assess.* 46 (2021), 101208.
- [16]. A. Ullah et al, Smart cities: the role of Internet of Things and machine learning in realizing a data-centric smart environment, *Survey and State of the Art*, Open access, Published: 27 July 2023, Volume 10, pages 1607–1637, (2024).
- [17]. P. Wu et al, Deep learning solutions for smart city challenges in urban development, *scientific reports articles*, Open access, Published: 02 March 2024.
- [18]. Yuan, et al. (2021). Energy Consumption Forecasting with CNN-LSTM Hybrid Model in Smart Cities.
- [19]. Machine learning based system for managing energy efficiency of public sector as an approach towards smart cities
- [20]. M. Zekić et al, Comparative study of univariate and multivariate strategy for short-term forecasting of heat demand density: Exploring single and hybrid deep learning models, *International Journal of Information Management*, 2024.
- [21] [www.kaggle.com/datasets/thaichi/jerichoeusage-dataset-single-original-data?select=nuts2\\_hourly\\_mob\\_service\\_Trui\\_semi\\_km.csv](https://www.kaggle.com/datasets/thaichi/jerichoeusage-dataset-single-original-data?select=nuts2_hourly_mob_service_Trui_semi_km.csv)

## A new method to improve energy consumption in a smart city using deep learning

**Azadeh Mansouri**

Lamei Gorgani Institute of Higher Education, Gorgan, Iran

azadehemansouri@gmail.com

**Reza Roshani**

Department of Computer Engineering, National University of Skills (NUS), Tehran, Iran  
, Lamei Gorgani Institute of Higher Education, Gorgan, Iran

r.roshany@gmail.com

### Abstract

Nowadays, due to the increase in energy demand, the optimal management of energy consumption has become one of the main challenges in smart cities. This research is an important step towards making energy management smarter in smart cities. In this research, a hybrid model based on deep learning, convolutional neural networks (CNN) and long-short-term memory (LSTM) neural network is proposed to accurately predict energy consumption. By combining these two models, it is possible to have a more accurate prediction of future energy consumption and to make better decisions for energy management by identifying complex patterns of energy consumption and providing solutions to optimize energy consumption. First, energy consumption data is collected from various sources such as sensors and smart meters, then data preprocessing is done to prepare them for model training, and CNN is used to extract spatial features from energy consumption data and LSTM is used to understand the temporal patterns of these data and predict energy consumption. . The proposed method has advantages such as high accuracy of energy consumption prediction, identification of complex patterns in energy consumption, the possibility of making better decisions for energy management, helping to reduce energy consumption and improving environmental sustainability.

**Keywords:** Smart City, Deep Learning, Convolutional Neural Networks, Long-Short-Term Memory Neural Network, Energy Consumption Prediction, Energy Optimization.