

## بهینه‌سازی زمان آموزش مدل چندوجهی GPT-CNN-PTEN برای پیش‌بینی قیمت بیت‌کوین با استفاده از موازی‌سازی داده و محاسبات دقت ترکیبی

امیرمحمد نبوی

کارشناسی ارشد، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، واحد ساری، ایران

[Am\\_nabavi@hotmail.com](mailto:Am_nabavi@hotmail.com)

دکتر کیمیا رضایی کلانتری

استادیار، گروه مهندسی کامپیوتر، واحد ساری، دانشگاه آزاد اسلامی، ساری، ایران

[rezaeikalantari@gmail.com](mailto:rezaeikalantari@gmail.com)

### چکیده

با تشدید تورم جهانی و کاهش قدرت خرید ارزهای رایج، ارزهای دیجیتال به‌عنوان گزینه‌ای بالقوه برای جایگزینی پول کاغذی مورد توجه قرار گرفته‌اند و این امر موجب افزایش چشمگیر تقاضا برای آن‌ها شده است. در این میان، پیش‌بینی قیمت بیت‌کوین به دلیل نوسانات شدید بازار و تأثیرپذیری از عوامل اقتصادی، سیاسی و رفتاری متعدد، به یکی از چالش‌برانگیزترین مسائل در حوزه مالی و یادگیری ماشین تبدیل شده است. در این راستا، مدل GPT-CNN-PTEN به‌عنوان یکی از معماری‌های پیشرفته یادگیری عمیق چندوجهی، توانسته است دقت قابل قبولی در پیش‌بینی قیمت ارائه دهد؛ با این حال، زمان بر بودن فرآیند آموزش این مدل همچنان به‌عنوان یک چالش اساسی مطرح است. در این پژوهش، با هدف کاهش زمان آموزش مدل GPT-CNN-PTEN، از تکنیک‌های موازی‌سازی داده و محاسبات دقت ترکیبی روی دو پردازنده گرافیکی NVIDIA Tesla T4 استفاده شده است. نتایج نشان داد که روش پیشنهادی زمان آموزش را مقدار قابل توجهی بهبود داد. کیفیت پیش‌بینی نیز حفظ شده. این پژوهش نشان داد که ترکیب موازی‌سازی داده و محاسبات دقت ترکیبی رویکردی مؤثر برای شتاب‌دهی آموزش مدل‌های یادگیری عمیق چندوجهی است.

**کلیدواژه‌ها:** پیش‌بینی قیمت بیت‌کوین، یادگیری عمیق چندوجهی، موازی‌سازی داده، محاسبات دقت ترکیبی، ترنسفورمر

### مقدمه

در دهه‌های اخیر، نظام مالی جهانی با تحولات عمیقی مواجه شده است. ظهور ارزهای دیجیتال بر بستر بلاک‌چین، امکان انجام تراکنش‌های امن و بدون واسطه را فراهم کرده است. بیت‌کوین به‌عنوان پیشگام این حوزه، با ارزش بازار بیش از یک تریلیون دلار،

نقش محوری ایفا می‌کند. [1] با تشدید تورم جهانی و کاهش قدرت خرید ارزهای فیات، تقاضا برای بیت‌کوین به شدت افزایش یافته است. با این حال، نوسانات شدید قیمتی بیت‌کوین، پیش‌بینی دقیق آن را به چالشی بزرگ تبدیل کرده است. مدل‌های سنتی مانند ARIMA یا SVM دقت محدودی دارند. مدل‌های یادگیری عمیق چندوجهی با ترکیب داده‌های قیمتی (OHLCV) و متنی (اخبار) عملکرد بهتری نشان داده‌اند. مدل GPT-CNN-PTEN (معرفی شده در سال ۲۰۲۵) یکی از پیشرفته‌ترین این معماری‌ها است که با رمزگذاری موقعیتی مبتنی بر CNN و ترکیب مدل‌های زبانی بزرگ، دقت بالایی ارائه می‌دهد [1].

با وجود دقت مناسب، زمان آموزش طولانی این مدل (حدود ۳۹۸ ثانیه روی P100) مانع کاربرد عملی، تنظیم فرآیندها و بازآموزی سریع است. این پژوهش به بررسی این سؤالات می‌پردازد:

1- آیا موازی‌سازی داده روی دو GPU T4 زمان آموزش را کاهش می‌دهد؟

۲- آیا محاسبات دقت ترکیبی سرعت را بدون افت کیفیت افزایش می‌دهد؟

۳- آیا ترکیب این دو تکنیک مزیت افزوده دارد؟

اهداف اصلی این تحقیق شامل بهینه‌سازی زمان آموزش با حفظ کیفیت، پیاده‌سازی روی سخت‌افزار در دسترس (T4 Kaggle) و ارائه راهکار عملی برای پژوهشگران با منابع محدود می‌باشد. نتایج این تحقیق می‌تواند پلتفرم‌های معاملات الگوریتمی، سیستم‌های پیش‌بینی رمزارز و پژوهش‌های دانشگاهی را بهره‌مند سازد.

## مبانی نظری

### معماری ترنسفورمر

معماری ترنسفورمر با مکانیزم توجه خودکار، پردازش موازی دنباله‌ها را ممکن می‌سازد. توجه چندسبب وابستگی‌های مختلف را همزمان مدل‌سازی می‌کند. [2]

### رمزگذاری موقعیتی

در مدل GPT-CNN-PTEN از شبکه کانولوشنی سه‌لایه برای یادگیری وابستگی‌های غیرخطی استفاده شده است (به جای روش سینوسی) [1].

### محاسبات دقت ترکیبی (AMP)

استفاده از FP16 برای محاسبات سنگین و FP32 برای عملیات حساس با GradScaler برای جلوگیری از سرریز Tensor .  
Core های T4 این تکنیک را تسریع می کنند [5] .

## روش پیشنهادی

روش پیشنهادی در این پژوهش با هدف کاهش زمان آموزش مدل چندوجهی GPT-CNN-PTEN بدون افت کیفیت پیش بینی طراحی شده است. ابتدا کد پایه مدل که در مقاله مرجع با TensorFlow پیاده سازی شده بود (به طور کامل به PyTorch مهاجرت شد تا از قابلیت های پیشرفته این چارچوب در زمینه موازی سازی و دقت ترکیبی بهره برداری شود. معماری مدل بدون تغییر باقی ماند و شامل سه رمزگذار اصلی است: رمزگذار متنی (Text Encoder) با چهار لایه ترنسفورمر و ۳۲ سر توجه برای پردازش جاسازی های ۱۵۳۶ بعدی اخبار، رمزگذار قیمتی (Price Encoder) با دو لایه و ۵ سر توجه برای داده های OHLCV پنج بعدی، و رمزگذار ترکیبی (Fusion Encoder) با دو لایه برای ادغام ویژگی ها. نوآوری کلیدی مدل یعنی رمزگذاری موقعیتی مبتنی بر شبکه کانولوشنی سه لایه نیز حفظ شد تا وابستگی های زمانی غیر خطی بازار بیت کوین به درستی مدل سازی شود [1] .

برای شتاب دهی آموزش، دو تکنیک اصلی به صورت هم افزا پیاده سازی گردید: موازی سازی داده با استفاده از nn.DataParallel روی دو پردازنده گرافیکی NVIDIA Tesla T4 و محاسبات دقت ترکیبی با torch.cuda.amp (Automatic Mixed Precision) همراه با GradScaler. اندازه دسته (Batch Size) از ۳۲ در روش مرجع به ۱۲۸ افزایش یافت تا ظرفیت Tensor Core های T4 به حداکثر برسد. علاوه بر این، بهینه سازی های تکمیلی شامل فعال سازی CuDNN Benchmark برای انتخاب خودکار بهترین الگوریتم ها، فعال سازی ۳۲ TF برای عملیات ماتریسی، استفاده از pin\_memory=True در DataLoader برای انتقال سریع تر داده،



<https://icaics.ir>  
[info@icaics.ir](mailto:info@icaics.ir)

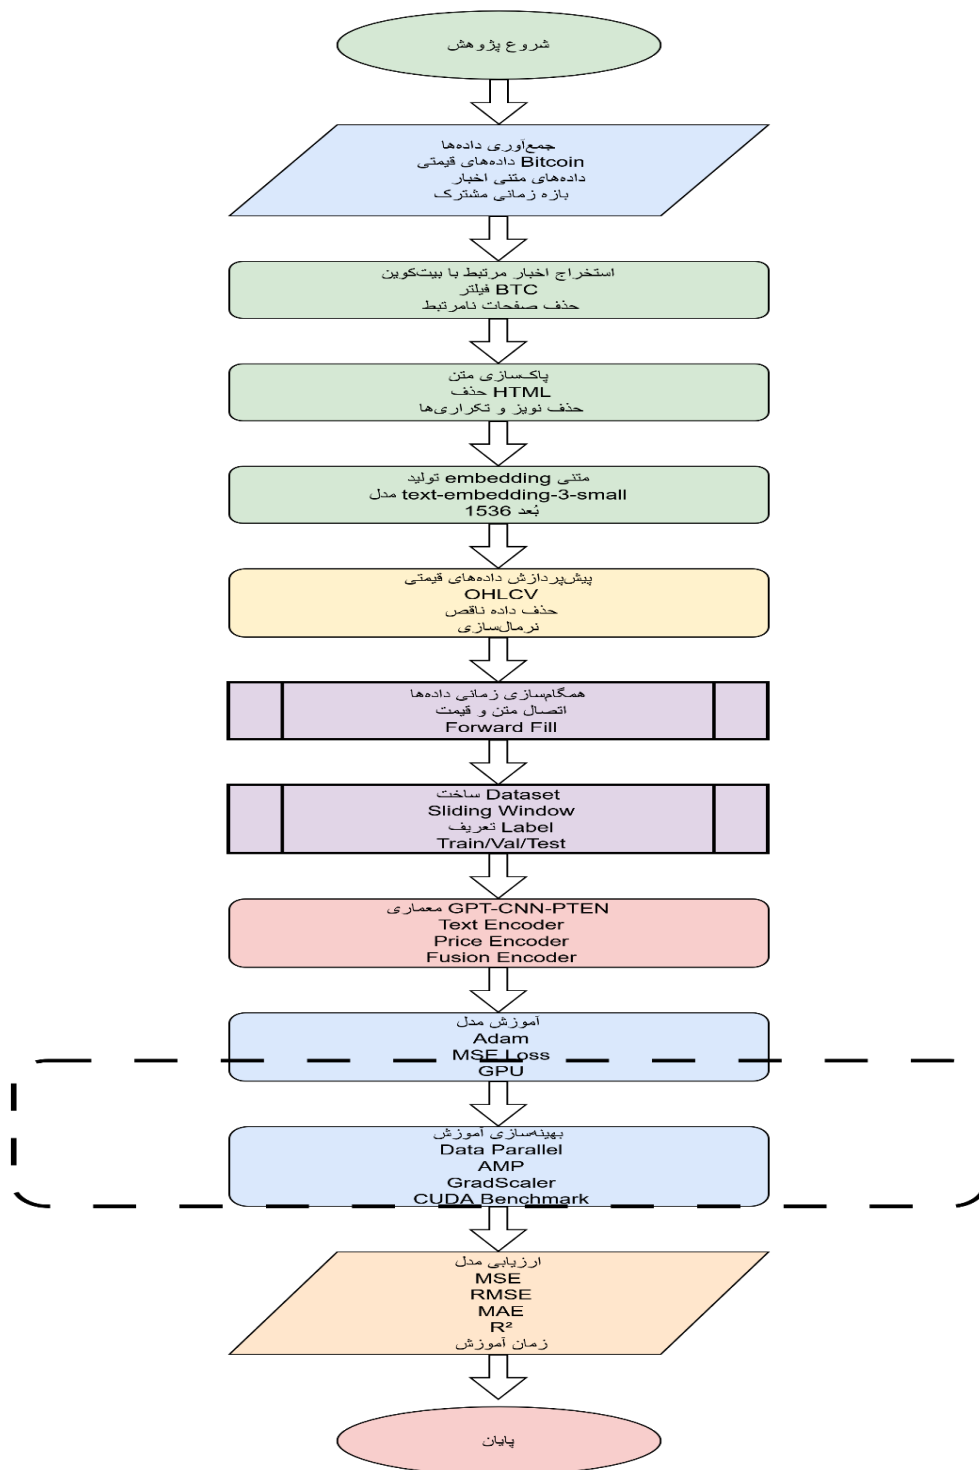
اولین کنفرانس بین المللی هوش مصنوعی  
و علوم کامپیوتری نو ظهور: از الگوریتم تا آینده نگر  
**First International Conference on Artificial Intelligence  
and Emerging Computer Science: From Algorithm to Foresight**

March 17, 2026-GEORGIA

۲۶ اسفند ماه ۱۴۰۴ - گرجستان

و Gradient Clipping با  $\max\_norm=1.0$  برای پایداری آموزش اعمال شد. این ترکیب تکنیکها باعث د مدل در دوره ۱۵ به

بهترین نتیجه ( $MSE=0.0030$ ) برسد در حالی که در روش مرجع این نقطه در دوره ۹۸ حاصل می شد..



شکل ۱: فلوچارت فرآیند تحقیق

## شبیه سازی و ارزیابی

ارزیابی انجام شده در ادامه ارائه خواهد شد.

جدول ۱: مشخصات سخت افزاری

مشخصه	روش مرجع	روش پیشنهادی
پردازنده گرافیکی	NVIDIA P100	۲× NVIDIA Tesla T4
تعداد GPU	۱	۲
حافظه GPU	۱۶ گیگابایت HBM <sup>۲</sup>	۱۵.۶۴ گیگابایت GDDR <sup>۶</sup> × ۲
معماری	Pascal	Turing
Compute Capability	۶.۰	۷.۵
پشتیبانی از Tensor Core	خیر	بله
پهنای باند حافظه	۷۳۲ GB/s	۳۲۰ × ۲GB/s
توان محاسباتی ۳۲FP	۱۰.۶ TFLOPS	۸.۱ × ۲TFLOPS
توان محاسباتی ۱۶FP	۲۱.۲ TFLOPS	۶۵ × ۲TFLOPS
پلتفرم اجرا	Kaggle	Kaggle



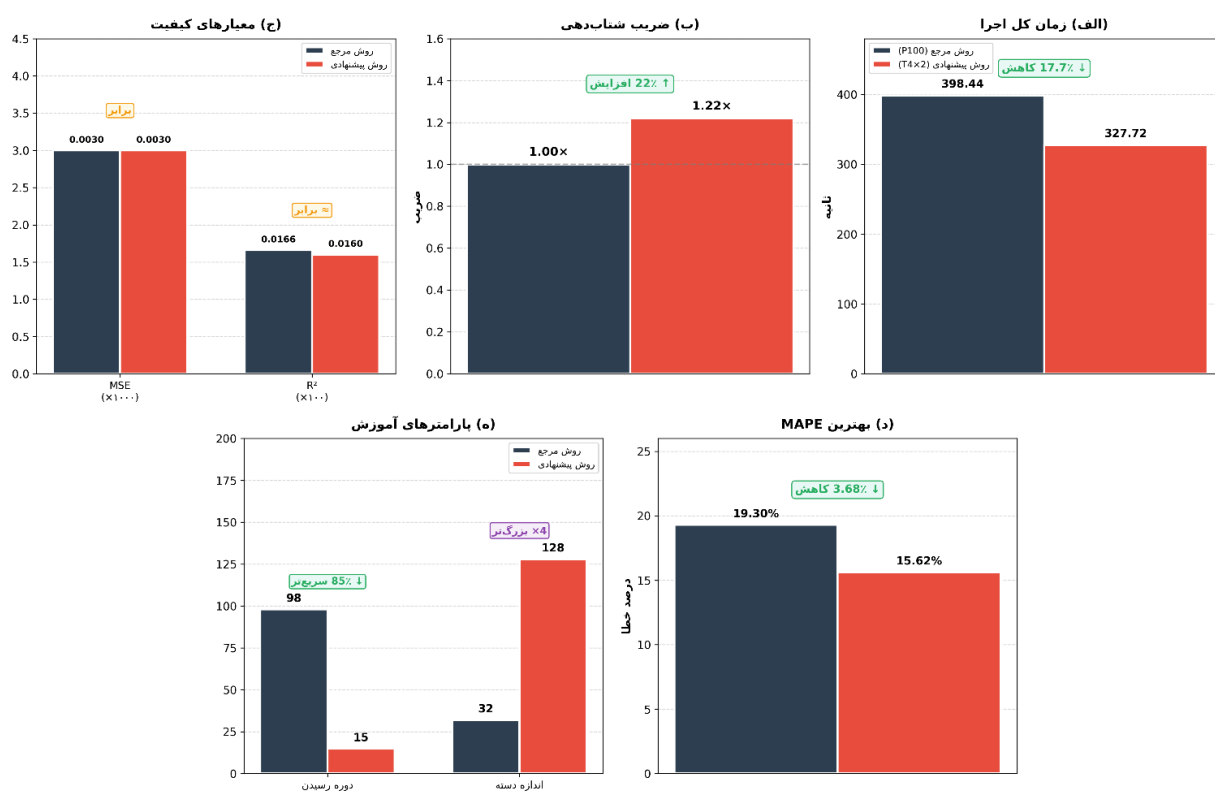


شکل ۲: نمودار مقایسه زمان اجرا و ضریب شتابدهی

جدول ۲: مقایسه معیارهای کیفیت

معیار	روش مرجع (P100)	روش پیشنهادی (T4×۲)	وضعیت
MSE	۰.۰۰۷۷	۰.۰۰۳۰	بهبود
R <sup>2</sup>	۰.۰۱۶۶	۰.۰۱۶۰	بهبود
RMSE	۰.۰۸۷۹	۰.۰۵۵ (تقریبی)	بهبود

معیار	روش مرجع (P100)	روش پیشنهادی (T4x2)	وضعیت
MAPE	۲۶.۹۵ درصد	۱۵.۶۲ درصد	بهبود



شکل ۳: نمودار روند آموزش و همگرایی

تحلیل نشان داد روش پیشنهادی در دوره ۱۵ به بهترین نتیجه رسید (در مقابل دوره ۹۸ در روش مرجع).

نتیجه‌گیری



این پژوهش با ارائه روش پیشنهادی مبتنی بر موازی‌سازی داده و محاسبات دقت ترکیبی روی دو GPU T4، شتابدهی ۱۰۲۲ برابری (کاهش ۱۷۰۷ درصدی زمان) را بدون افت کیفیت (MSE ثابت ۰۰۰۰۳۰) و حتی بهبود MAPE به دست آورد. نتایج فرضیه‌ها را تأیید کرد و برتری روش پیشنهادی را نسبت به روش مرجع نشان داد.

## پیشنهادهای برای تحقیقات آینده

با توجه به تحقیق انجام شده، پیشنهادات زیر بمنظور کار آتی میتواند ارائه گردد:

استفاده از DistributedDataParallel به جای DataParallel

آزمایش روی مجموعه داده‌های بزرگ‌تر

ترکیب با تکنیک‌های فشرده‌سازی مدل (Quantization)

ارزیابی روی سخت‌افزارهای متنوع (A100)، (H100)

مقایسه با مدل‌های زبانی بزرگ دیگر

## منابع

- [۱] Vardhan, G. V., & Subburaj, B. (۲۰۲۵). Multimodal deep learning model for bitcoin price prediction.
- [۲] Vaswani, A., et al. (۲۰۱۷). Attention is all you need. NeurIPS.
- [۳] Liu, X.-Y., et al. (۲۰۲۳). FinGPT: Democratizing internet-scale data for financial LLMs.
- [4] Ben-Nun, T., & Hoefler, T. (۲۰۱۹). Demystifying parallel and distributed deep learning.
- [5] Micikevicius, P., et al. (۲۰۱۸). Mixed precision training. ICLR.