

REZUMAT

În ultimii ani, ecosistemul inteligenței artificiale a înregistrat progrese remarcabile, iar anul 2025 marchează un punct de cotitură, generat de competiția acerbă dintre principalii furnizori de tehnologie. Această rivalitate stimulează apariția unor modele din ce în ce mai performante și pune la dispoziția comunității științifice un portofoliu vast de unelte de tip „off-the-shelf”, care accelerează dezvoltarea soluțiilor academice. În paralel, proliferarea opțiunilor de modele – cu grade diferite de complexitate și eficiență – creează însă provocări serioase în selecția celor mai potrivite instrumente pentru aplicații concrete. Lucrarea de față răspunde acestei provocări printr-o analiză comparativă (benchmark) a unor modele de inteligență computațională destinate prognozei seriilor temporale. Abordarea propusă urmărește o evoluție „generațională” a metodelor analizate: de la tehnici statistice clasice, prin rețele neuronale convenționale, până la arhitecturi de tip *transformers*. Studiul include seturi de date diverse — de la fluctuațiile indicelui S&P 500 și dinamica acțiunilor AAPL, până la consumul de energie electrică din România — pentru a verifica robustețea și versatilitatea fiecărei categorii de modele. Rezultatele obținute evidențiază că pentru anumite cazuri (de exemplu, seria de consum de energie electrică), modelele *transformers* de ultimă generație oferă un ușor avantaj în ceea ce privește acuratețea prognozei, deși nu cu diferențe majore față de rețelele neuronale clasice. În mod surprinzător, arhitecturi precum N-BEATS sau N-HITS concurează îndeaproape cu variante mai noi (TimeFM, TimeGPT, Amazon Chronos, Mamba ș.a.), demonstrând că soluțiile „bine cunoscute” rămân competitive. Prin această analiză de tip *benchmark*, contribuția principală constă în identificarea celor mai eficiente modele pentru predicție în funcție de specificul datelor și de costurile de calcul implicate, oferind cercetătorilor o hartă clară pentru alegerea optimă a algoritmilor în proiectele viitoare.

SUMMARY

In recent years, the artificial intelligence ecosystem has made remarkable progress, and 2025 marks a turning point, driven by fierce competition between the major technology vendors. This rivalry is spurring the emergence of better and better models and providing the scientific community with a vast portfolio of off-the-shelf tools that accelerate the development of academic solutions. In parallel, however, the proliferation of modeling options - with varying degrees of complexity and efficiency - creates serious challenges in selecting the most suitable tools for concrete applications.

In parallel, however, the proliferation of modeling options - with varying degrees of complexity and efficiency - creates serious challenges in selecting the most suitable tools for concrete applications. This paper addresses this challenge by benchmarking computational intelligence models for time series forecasting. The proposed approach follows a "generational" evolution of the analyzed methods: from classical statistical techniques, through conventional neural networks, to transformer architectures. The study includes diverse datasets - from the fluctuations of the S&P 500 index and the dynamics of AAPL shares, to the electricity consumption in Romania - in order to verify the robustness and versatility of each category of models. The results show that, for some cases (e.g., the energy consumption series), state-of-the-art transformer models offer a slight advantage in terms of forecasting accuracy, although not with major differences compared to classical neural networks. Surprisingly, architectures such as N-BEATS or N-HITS compete closely with newer variants (TimeFM, TimeGPT, Amazon Chronos, Mamba, etc.), demonstrating that "well-known" solutions remain competitive. Through this benchmark analysis, the main contribution is to identify the most efficient models for prediction according to the specific data and computational costs involved, providing researchers with a clear roadmap for the optimal choice of algorithms in future projects.