



Universiteit
Leiden
The Netherlands

Machine learning and deep learning approaches for multivariate time series prediction and anomaly detection

Thill, M.

Citation

Thill, M. (2022, March 17). *Machine learning and deep learning approaches for multivariate time series prediction and anomaly detection*. Retrieved from <https://hdl.handle.net/1887/3279161>

Version: Publisher's Version

License: [Licence agreement concerning inclusion of doctoral thesis in the Institutional Repository of the University of Leiden](#)

Downloaded from: <https://hdl.handle.net/1887/3279161>

Note: To cite this publication please use the final published version (if applicable).

Samenvatting

Tot op heden blijft anomaliedetectie in het algemeen en in het bijzonder voor temporele data zoals datastromen of tijdreeksen een uitdagende taak. Toch wordt anomaliedetectie in tijdreeksen steeds belangrijker in vele domeinen. Zo zijn bijvoorbeeld meer en meer industriële machines uitgerust met talrijke sensoren voor conditiebewaking en predictieve onderhoudstoepassingen, die grote hoeveelheden data produceren in de kortst mogelijke tijd. Bij dergelijke toepassingen is het van cruciaal belang deze grote gegevensstromen voortdurend te bewaken en afwijkend gedrag in een vroeg stadium te detecteren om uitval van kritische systemen en eventuele verdere schade te voorkomen. Ook in veel andere toepassingsgebieden (bijv. servertechnologieën & netwerken, hoge-energiefysica & astronomie, of systemen voor gezondheidsbewaking) worden enorme hoeveelheden gegevens verzameld, die automatisch moeten worden geanalyseerd met geschikte algoritmen. In deze context ontstond de noodzaak voor nauwkeurige en robuuste unsupervised learning methoden voor anomaliedetectie.

In dit proefschrift presenteren en bespreken we verschillende algoritmes voor onbewaakte anomaliedetectie voor tijdreeksen.

Ons eerste algoritme, genaamd SORAD (Simple Online Regression for Anomaly Detection), wordt gepresenteerd in Hoofdstuk 4. SORAD leert een lineair regressiemodel om toekomstige waarden van een tijdreeks te voorspellen en schat tegelijkertijd het gemiddelde en de variantie van de voorspelfouten. Gegevenspunten met voorspelfouten die significant anders zijn van het gemiddelde worden als afwijkend beschouwd. SORAD kan volledig online (of met kleine batches) werken op elke tijdreeks na een korte transiënte fase en zich aanpassen aan veranderende concepten (als gevolg van het vergeten in het lineaire model en de schattingen van de voorspelfouten). Op de Webscope S5 anomalie benchmark [87] kon SORAD aanzienlijk beter presteren dan andere algoritmen. SORAD vertoonde echter tekortkomingen op de Numenta Anomaly Benchmark (NAB) [89], waar het aanvankelijk niet goed presteerde.

In hoofdstuk 5 hebben we het DWT-MLEAD (Discrete Wavelet Transform with Maximum Likelihood Estimation for Anomaly Detection in Time Series) algoritme geïntroduceerd. Het centrale idee van dit algoritme is het analyseren van een tijdreeks op verschillende frequentie/tijdschalen met behulp van de discrete wavelet-transformatie (DWT). DWT-MLEAD (i) berekent een decimerende DWT met gebruikmaking van Haar wavelets, (ii) schuift een venster over de afzonderlijke frequentieschalen en schat het gemiddelde en

de covariantiematrix van de verzamelde punten, en (iii) identificeert ongebruikelijke punten op basis van een Mahalanobis-afstand. Dan (iv) worden de ongebruikelijke punten gemarkeerd als gebeurtenissen en door de DWT-boom geleid. Tenslotte (v) worden de gebeurtenissen van alle frequentieschalen samengevoegd op de oorspronkelijke tijdschaal en zorgt het algoritme ervoor dat een anomalie wordt afgevuurd als een gespecificeerde drempel wordt overschreden. Door gebruik te maken van deze multischaalbenadering is het mogelijk anomalieën op korte en ook op langere termijn te detecteren. DWT-MLEAD was in eerste instantie ontworpen als offline algoritme, maar na enkele aanpassingen is gebleken dat het ook in een online omgeving kan worden gebruikt. We ontdekten dat DWT-MLEAD beter presteert dan andere state-of-the-art algoritmen op de Webscope S5 en de NAB data met slechts één hyperparameter instelling.

Het LSTM-AD algoritme, beschreven in Hoofdstuk 6, leert normaal tijdreeksgedrag te voorspellen met behulp van recurrente long short-term memory (LSTM) neurale netwerken. Het algemene idee in LSTM-AD is vergelijkbaar met dat van SORAD. Het breidt het echter op verschillende punten uit: In plaats van een eenvoudig lineair regressiemodel te gebruiken, gebruikt LSTM-AD een stapel LSTM-lagen om meer ingewikkelde temporele patronen te leren. Bovendien worden nu 25 voorspellingshorizonten gebruikt in plaats van slechts één. De voorspellingsfouten voor verschillende voorspellingshorizonten worden gebruikt om afwijkend gedrag aan te geven (waarbij de Mahalanobis-afstand van de voorspellingsfouten als anomaliescore wordt gebruikt). Verschillende extra uitbreidingen, zoals een venstergebaseerde foutcorrectie en een niet gesuperviseerde methode voor het verwijderen van uitschieter worden geïntroduceerd. LSTM-AD werd geëvalueerd op de bekende MIT-BIH ECG-gegevensset en kon goede eerste resultaten behalen. Later, in hoofdstuk 7, worden nog betere resultaten gevonden met een verbeterde hyper-parameter selectie.

In hoofdstuk 7 wordt de Temporal Convolutional Network Autoencoder (TCN-AE) geïntroduceerd. Het hoofdidee is om een TCN [13] te gebruiken als encoder netwerk en een ander TCN als decoder netwerk. Om een knelpunt te creëren, wordt in de encoder de tijdreeks gedownsampled en de dimensionaliteit gereduceerd. Nadat de ingevoerde tijdreeks is gecodeerd tot een gecomprimeerde reeks, tracht een temporaal decodernetwerk de oorspronkelijke invoer te reconstrueren. TCN maakt gebruik van zogenaamde gedilateerde convoluties, die hun oorsprong vinden in discrete wavelet transformaties en een exponentieel toenemend receptief veld creëren met slechts een lineaire toename van het aantal trainbare gewichten. Wij hebben onze eerste experimenten uitgevoerd met een relatief eenvoudige basis TCN-AE architectuur. De baseline TCN-AE toonde aan dat het al interessante representaties van verschillende Mackey-Glass tijdreeksen kon leren, en dat het goed presteerde op de Mackey-Glass Anomaly Benchmark (MGAB). We merkten echter een paar tekortkomingen op, die we in die we in later onderzoek hebben aangepakt. We toonden aan dat verschillende uitbreidingen van het basismodel van cruciaal belang zijn om de algemene prestaties te verbeteren. TCN-AE in zijn uiteindelijke vorm levert significant betere resultaten op op de MIT-BIH ECG data, en presteert beter dan andere state-of-the-art algoritmen. Tegelijkertijd vermindert het de rekentijd en het aantal trainbare parameters (in vergelijking met baseline TCN-AE).