

Anomáliák Észlelése Vízellátó Rendszerekben

Identification of Irregularities In Water Distribution Networks

Zoltán CZAKO¹, Gheorghe SEBESTYEN², Anca HANGAN³

Számítástechnikai Tanszék, Kolozsvári Műszaki Egyetem, Kolozsvár, Románia

¹zoltan.czako@cs.utcluj.ro, ²gheorghe.sebestyen@cs.utcluj.ro, ³anca.hangan@cs.utcluj.ro

Abstract

Anomaly detection in water supply infrastructures is an important aspect that influences the proper functioning and the security of the entire system. Making the difference between a normal and an abnormal behavior is not a simple task; it requires machine learning (ML) techniques and artificial intelligence (AI) algorithms. This paper presents an automated method of selecting and tuning the best AI model that has the ability to classify the input data as normal or abnormal.

Keywords: Drinking-water quality, Anomaly Detection, Artificial Intelligence (AI), AutomaticAI

Kivonat

Az anomáliák észlelése a vízellátó infrastruktúrákban fontos szempont, amely befolyásolja a teljes rendszer megfelelő működését és biztonságát. A normális és az abnormális viselkedés között különbséget tenni nem egyszerű feladat; gépi tanulási (ML) technikákat és mesterséges intelligencia (AI) algoritmusokat igényel. Ez a cikk egy automatizált módszert mutat be a legjobb mesterséges intelligencia-modell kiválasztására és paramétereinek beállítására, amely képes a bemeneti adatokat normálisnak vagy abnormálisnak minősíteni.

Kulcsszavak: Ivóvíz Minőség, Anomáliák Észlelése, Mesterséges Intelligencia (AI), AutomaticAI

1. BEVEZETŐ

A víz jelentős erőforrás egy nemzet számára, és kezelése befolyásolhatja egy régió társadalmi és gazdasági fejlődését. A múlt században a földkerekség számos régióját drasztikusan befolyásolta a vízhiány vagy az ivóvíz rossz minősége. A globális felmelegedés súlyosbítja a vízzel kapcsolatos problémákat, és a jövőben ezek a problémák kritikussá válnak.

A modern világban a minőségi víz biztosítása és a szennyvíz újrahasznosítása (geo)politikai stratégiákat és technológiai megoldásokat igényel. A víz körforgásának minden szakaszában, a begyűjtéstől és kezeléstől az elosztásig és újrahasznosításig komplex kiberfizikai rendszereknek kell egyensúlyt teremteniük a kereslet és a kínálat között, és garantálniuk kell a nemzeti és nemzetközi szabványoknak megfelelő minőségi paramétereket. Ebben az összefüggésben nagy kihívást jelent a normálisnak tekintett állapottól való bármely eltérés automatizált azonosítása, más szóval az anomáliák észlelése. A vízrendszer anomáliájának hatásai a lakosság jelentős részének jólétét és egészségbiztonságát befolyásolhatják. Ezért minden incidenst (meghibásodást) a lehető legrövidebb időn belül észlelni kell, és lehetőség szerint automatizált módon helyreállítási intézkedéseket kell indítani.

Az anomáliák észlelése a vízrendszerekben, valamint bármely más kiberfizikai rendszerben nem triviális feladat. Ha emberi közreműködéssel készül, akkor sok éves tapasztalatra, technikai készségekre és néha intuícióra van szükség. Az automatizált rendszerekben az emberi tapasztalatból történő anomáliák azonosítását mesterséges intelligencia modellekkel helyettesíthetik, amelyek képesek azonosítani és megtanulni a szükséges szabályokat. Ezt a megközelítést összetett viselkedésű, többváltozós rendszerek esetén alkalmazzuk.

Ez a cikk egy automatizált módszert mutat be a legjobb mesterséges intelligencia-modell kiválasztására és paramétereinek beállítására, amely képes a bemeneti adatokat normálisnak vagy abnormálisnak minősíteni, tehát felhasználható anomáliák észlelésére komplex vízrendszerekben.

2. KAPCSOLODÓ MUNKÁK

A vízrendszerek anomáliáinak észlelését számos cikk tanulmányozta, a szerzők különböző célokat és megközelítéseket javasoltak. Célként említhetjük a vízminőség-ellenőrzést [1][2][3], az infrastruktúra integritását, a megszerzett adatok helyességét vagy a rosszindulatú támadások észlelését [4][5]. Megoldásként megkülönböztethetünk idősorokhoz kapcsolódó módszereket (pl. regressziós és előrejelzés alapú módszerek), illetve osztályozáson alapuló módszereket. Az utolsó kategóriában számos mesterséges intelligencia módszert javasoltak a vízrendszer normál és deviáns viselkedésének modellezésére. A gépi tanulási technikákat olyan modell betanítására használták, amely képes azonosítani az anomáliákat az összegyűjtött adatkészletben, offline módon vagy akár valós időben.

Számos általános osztályozási módszert sikeresen teszteltek az anomáliák kimutatására kifejezetten a vízrendszerek anomáliáira összpontosítva. A [1] szerzői különböző osztályozási módszereket használnak, mint például döntési fák, logisztikai modellfák, véletlenszerű erdők és hoeffding fák, hogy osztályozzák a víz minőségét néhány mért paraméter, például lúgosság, pH-szint és vezetőképesség alapján. A j48 elnevezésű módszer, egy prediktív öntanuló döntési fa (a weka csomagból kölcsönzött) bizonyult a legnagyobb pontosságúnak, körülbelül 94%-os pontossággal.

A Szingapúri Műszaki Egyetemen egy Secure Water Treatment Testbed-et (SWaT) [4] fejlesztettek ki a víztisztító infrastruktúra rosszindulatú támadások alatti viselkedésének tanulmányozására. A tesztágy minden olyan fokozatot és berendezést tartalmaz, amely egy igazi tisztítóállomásra jellemző. A SWaT-ből különböző feltételek mellett gyűjtött adatkészletek nyilvánosak a tudományos közösség számára. Egy másik, ugyanazon egyetem által kínált tesztágy laboratóriumi körülmények között szimulál egy vízelosztó infrastruktúrát [5].

A [6] cikkben a szerzők számos gépi tanulási modellt alkalmaztak, például logisztikus regressziót, lineáris diszkriminanciaanalízist, SVM-et, ANN-t, DNN-t (mély neurális hálózat), RNN-t (ismétlődő neurális hálózat) és LSTM-et (hosszú rövid távú memória) azonosítani a vízminőségi anomáliákat egy valós városi vízinfrastruktúrából származó adatkészletben. A gépi tanulási technikák mellett a szerzők bemutatják a bemeneti adatok szűréséhez és előfeldolgozásához szükséges problémákat és megoldásokat a zaj, a hiányzó minták és a valós adatokra jellemző egyéb problémák kiküszöbölésére. Ebben a kísérletben az SVM-modell teljesített a legjobban, a legtöbb valós pozitívát azonosította, hamis pozitívumot nem generált, és 0,989 F1 metrika értéket ért el. A fő nehézsége ezen problémának az volt, hogy a mért vízminőségi paraméterek (redox, pH, vezetőképesség, zavarosság stb.) önmagukban nem utalhatnak vízminőségi anomáliára, csak ezek meghatározott kombinációi.

Mindezeket az eredményeket elemezve megállapítható, hogy a vízi infrastruktúrák anomáliái nagy pontossággal kimutathatók SVM, ANN, döntési fák, ensemble módszerek, rajoptimalizáló és regressziós modellek vagy ezek kombinációi segítségével. A jó eredmények elérése érdekében ezeket a modelleket valós infrastruktúrákból gyűjtött adatokkal kell képezni. A korábban bemutatott példákban található legjobb detektálási algoritmusok nagymértékben függenek a mért paramétereiktől, az anomáliák gyakoriságától és a bemeneti adatok minőségétől. Ezért ebben a versenyben nincs egyetlen győztes.

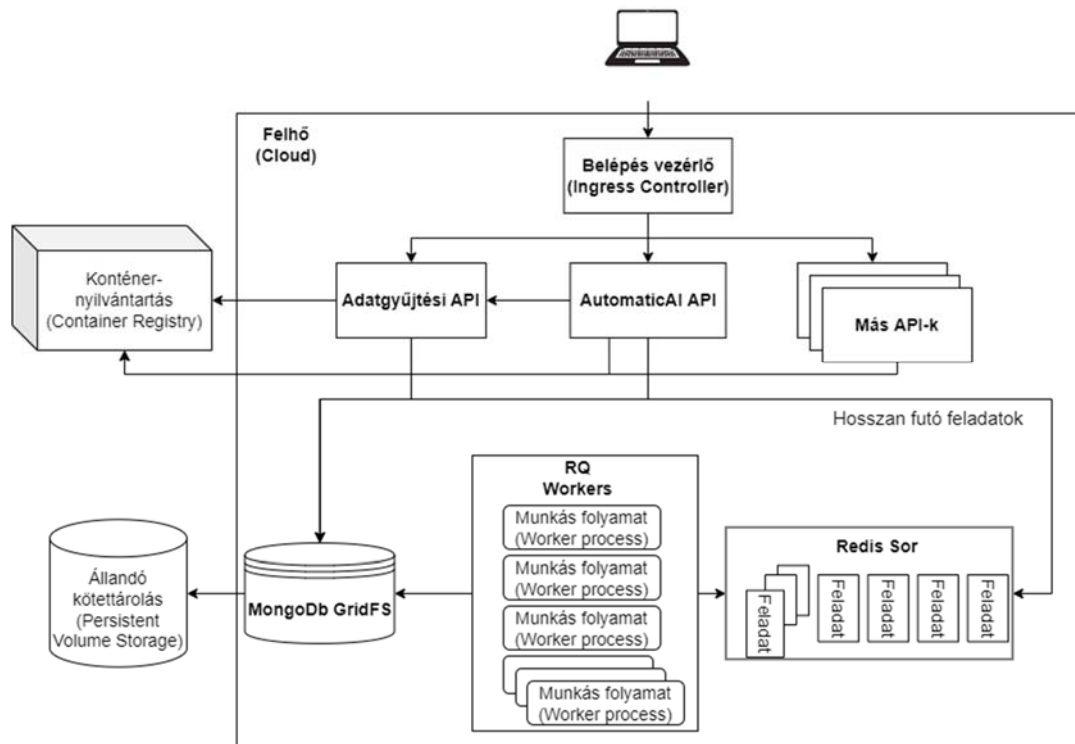
Ebben a cikkben egy automatikus módszert javasolunk, amely kiválasztja a legjobban teljesítő algoritmust egy adott adatkészlet alapján. Ez a módszer úgy hangolja a talált algoritmusok hiperparamétereit, hogy maximalizálja az adott esethez fontosnak tartott metrikákat.

3. AZ ANOMÁLIÁT DETEKTÁLÓ ALGORITMUS AUTOMATIKUS KIVÁLASZTÁSA ÉS PARAMÉTEREINEK BEÁLLÍTÁSA

Ezt a munkát megelőzően kifejlesztettünk egy [7] platformot, amely magában foglalja az összes szükséges módszert és algoritmust anomáliák észlelésére [8]. Megterveztünk egy algoritmust, amely automatikusan kiválasztja a legjobb modellt, és beállítja annak hiperparamétereit emberi beavatkozás nélkül, és az anomália észlelő platform kiegészítő elemeként implementáltuk. Ez az algoritmus a részecske-raj-optimalizálást kombinálja a szimulált lágyítással, hogy kizárólag a bemeneti adatok alapján keresse meg a legjobb modellt. Az anomáliaészlelési platform vagy másnéven AutomaticAI architektúrája (lásd: 1-es ábra) mikroszolgáltatások fürtjeként épül fel, és egy felhő-infrastruktúrán van telepítve.

Több AI modell kiértékelése komoly feldolgozási teljesítményt igényel, ezért a folyamat felgyorsítása érdekében különböző párhuzamos számítási technikákat alkalmaztunk. Rendszerünket több szolgáltatásra osztjuk. Így minden szolgáltatás más-más csomóponton futhat, és mindegyik egyedileg méretezhető, a

munkaterhelés alapján. Az összes szolgáltatás automatikus összehangolásához és irányításához a Kuberneteset használtuk Docker-tárolókkal.



1. ábra. Az anomáliák észlelésére szolgáló platform architektúrája

4. KÍSÉRLETI EREDMÉNYEK

A vízminőségi anomáliák kiszűrése érdekében kutatásunkat a GECCO 2017 [9] adatkészletén végeztük. Ez az adatkészlet több mint 100 000 példát tartalmaz az ivóvízzel kapcsolatos valós adatokra, 9 mért attribútumot és egy céloszlopot tartalmaz, mely egy bináris érték, amely azt jelzi, hogy történt-e jelentős változás a vízminőségben vagy sem. A mért attribútumok a következők:


- Tp - a víz hőmérsékletét jelöli Celsius fokban
- Ph - a víz pH-értéke
- Leit - elektromos vezetőképesség
- Trueb – a víz zavarossága
- Redox – redox potenciál
- Cl, cl_2 - klór-dioxid
- Fm, fm_2 – áramlási sebesség

A fent bemutatott értékek nagyon jó vízminőségi mutatók. Például a vízben oldott szilárd anyagok mennyisége határozza meg az elektromos vezetőképességet, így ez a víz minőségének jó mutatója. A zavarosság a folyadék relatív átlátszóságának mutatója. A víz zavarossága alapján agyag, iszap, nagyon kicsi szerves és szerves anyagok, például mikroorganizmusok mutathatók ki. Ha az ivóvíz pH-járól beszélünk, a pH normál tartománya általában 6,5 és 8,5 között van.

A fő cél ebben az esetben az adatkészlet változásainak/eseményeinek észlelése. Mivel ezek a változások ritkák, az adatkészlet erősen kiegyensúlyozatlan, így a probléma anomália-észlelési problémának tekinthető.

Az AI/ML modellek teljesítményének növelése érdekében jó ötlet a nyers adatok előfeldolgozása, mielőtt azokat egy osztályozási algoritmusba táplálnák. A zaj, a hiányzó adatok vagy az egyensúlyhiány negatívan befolyásolhatják az AI-modell teljesítményét.

A 2-es ábra azt az adat-előfeldolgozási folyamatot ábrázolja, amelyet az ivóvízminőségi adatkészlet előkészítéséhez használtunk. Mivel az adatkészlet minden oszlopában (átlagosan) körülbelül 10 000 hiányzó érték található, feltétlenül szükséges a hiányzó adatok kezelése. Többféle megközelítést is kipróbáltunk, először eltávolítottuk a hiányzó értékeket tartalmazó sorokat, de így túl sok értékes példát veszítettünk el. A következő próbálkozás az értékek átlaggal, medián értékkel vagy nullákkal való kitöltése volt. A legmegfelelőbb megoldás a hiányzó oszlopok nullákkal való kitöltése volt. Ez adta a modell legnagyobb teljesítményét.



2. ábra. Adat-előfeldolgozási folyamat lépései

Számos algoritmus létezik, például az SVM vagy a neurális hálózatok, amelyek esetében a különböző oszlopok eltérő skálája negatívan befolyásolhatja a modell teljesítményét. A probléma megoldása érdekében az adatokat különböző transzformációs stratégiákkal átalakítottuk, mint például a min-max skálázás, a $[0, 1]$ intervallumban történő skálázás és a normalizálás. A legjobb eredményeket a $[0, 1]$ intervallumú vagy standard skálázás adta.

Az utolsó lépésben, mivel a bemeneti adatok erősen kiegyensúlyozatlanok, a SMOTE-t (Synthetic Minority Oversampling Technique) [10] használtuk a kisebbségi osztály túlmintavételezésére és a RUID (Random Under-sampling Imbalanced Datasets) [11] segítségével. Ezen algoritmusok futtatása után egy egymáshoz közelebbi címkeszámú adatkészletet kaptunk.

Az előfeldolgozott adatkészletet átadtuk az AutomaticAI platformnak, amely kiválasztotta a legjobb modellt és beállította a hiperparamétereit. A platform különböző algoritmusok összehasonlítására és párhuzamos értékelésére is használható. Több mesterséges intelligencia-algoritmus összehasonlítása után az eredmények az 1-es táblázatban láthatók.

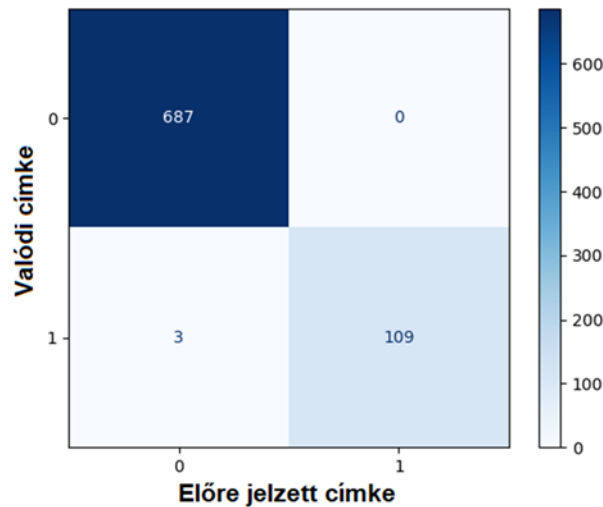
ALGORITMUSOK TELJESÍTMÉNYE

Algoritmus	f1 érték
RANDOM FOREST	99.93%
EXTRA TREES CLASSIFIER	99.81%
DECISION TREE	99.79%
MLP	99.49%
KNN	99.47%
One-Class SVM	81.46%
SGD CLASSIFIER	50.36%
LOGISTIC REGRESSION	49.66%
PASSIVE AGRESSIVE CLASSIFIER	45.36%
RIDGE CLASSIFIER	37.34%

1. Táblázat

Amint az az 1-es táblázatban látható, a platformnak sikerült automatikusan kiválasztania egy modellt és beállítania a hiperparamétereit. A kiválasztott modell a véletlenszerű erdő (Random Forest) volt, 99,93%-os


tesztelési f_1 -mértékkel és 99,49%-os érvényesítési f_1 -mértékkel (nem látott adatok felhasználásával). A még nem látott validációs adatokat használó konfúziós mátrix a 3-as ábrán látható.



3. ábra. Teszt adatok konfúziós mátrixa

Számos algoritmus létezik, amelyek hasonló eredményeket adtak, ilyen például véletlenszerű erdő, extra fa osztályozó vagy döntési fa. Ez normális, mert ezek az algoritmusok nagyon hasonlóak, mindegyik fa alapú ensemble metódus. A többrétegű perceptron is magas f_1 -pontszámot generált. Ezt a pontszámot úgy kaptuk meg, hogy 9 teljesen összekapcsolt réteget használtunk, 512 csomóponttal kezdtünk, majd a következő rétegekben a csomópontok számát 2 hatványával csökkentettük, így a következő rétegekben 256, 128, 64, 32, 16, 8, 4, az utolsó rétegben pedig 2 csomópontot használtunk a két osztály osztályozásához. Még ha az MLP osztályozó magas f_1 -pontszámot is kapott, az edzési idő jóval magasabb, mint a véletlenszerű erdő vagy extra fa osztályozó esetében, így összességében ennek a versenynek a nyertese a véletlenszerű erdő lett.

A kiválasztott modell eredményeinek magyarázatához és megértéséhez a jellemzők fontosságát használtuk, amely az egyes jellemzők relatív fontosságát méri előrejelzéskor (lásd a 4-es ábrát).



4. ábra. Az egyes attribútumok fontossági értékei: $Tp=0,054$, $Cl=0,120$, $pH=0,128$, $Redox=0,238$, $Leit=0,147$, $Trueb=0,061$, $Cl_2=0,141$, $Fm=0,035$, $Fm_2=0,072$

Amint az ábrán is látható, az ivóvíz minőségi anomáliák kimutatásának legfontosabb jellemzője vagy attribútuma a redox, más szóval az oxidációs redukációs potenciál, amely jelzi, hogy a víz mennyire fertőtlenített vagy szennyezett az oxidációja és redukciója alapján. Ez egy nagyon jó mérőszám a vízminőség becsléséhez, ezért minden vízminőség-ellenőrző rendszernek ORP-mérőket kellene használnia.

A jellemzők fontosságának második helyére több attribútumunk van, amelyek nagyon közeli fontossági értékekkel rendelkeznek, például pH, Cl, Cl_2 és Leit. Azért sejtettük ezt az eredményt, mert például a klór-dioxidot (cl és cl_2) fertőtlenítőként, valamint szag- és ízszabályozásra használják vízben és élelmiszerek higiénijában, így ez jó mutatója lehet a vízminőségnek. A pH-érték szintén a vízminőség jó mutatója, mert az ivóvíz pH-értéke 6,5 és 8,5 között kell hogy legyen. A nagyon alacsony vagy magas pH-érték a víz kémiai szennyezettségét jelezheti. A Leit attribútum a víz elektromos vezetőképessége. A vízben oldott szilárd anyagok mennyisége határozza meg az elektromos vezetőképességet, így ez is jó mutatója a víz minőségének.

A legkevésbé fontos jellemzők az FM és FM_2 attribútumok. Ez a két attribútum az áramlási sebességet jelzi, ami valójában nem az ivóvíz minőségét jelzi, hanem azt, hogy egy adott időn belül mennyi víz jön ki a csapból. A víz zavarossága szintén alacsony jellemző fontosságú értékkel rendelkezik, ami annak a jele lehet, hogy ez az attribútum redundáns és kifejezhető az adatkészletben lévő egyéb attribútumok kombinációjával.

5. KÖVETKEZTETÉSEK

Ebben a cikkben röviden ismertettük anomália-észlelő platformunkat, és áttekintést adtunk az architektúráról. Ezt a platformot felhasználtuk az ivóvízminőség anomáliák észlelésének problémájának megoldására. Ennek a problémának a megoldására először felállítottunk egy előfeldolgozási folyamatot, amelyben a hiányzó adatproblémát több lehetséges megoldás kipróbálásával kezeltük, az adatokat átalakítottuk, majd az egyensúlyhiányt kezeltük SMOTE és RUID segítségével, az osztályozási modell teljesítményének növelése céljából.

A cikk utolsó részében bemutattuk a kísérleti eredményeket, amelyekben több AI algoritmus típus teljesítményét hasonlítottuk össze, és bemutattuk a platformunk által automatikusan kiválasztott és konfigurált modell eredményeit.

Az automatikusan kiválasztott algoritmus jól szemlélteti platformunk teljesítményét, mivel a hibrid PSO-SA algoritmusunk futtatásával minimális emberi beavatkozással 99% feletti f1-mértéket értünk el.

IRODALMI HIVATKOZÁSOK

- [1]. C. Gakii, J. Jepakoch, *A classification model for water quality analysis using decision tree*, European Journal of Computer Science and Information Technology, Vol.7, No.3, pp.1-8, June 2019
- [2]. F. Muharemi, D. Logofătu, and F. Leon, *Review on general techniques and packages for data imputation in r on a real-world dataset*, Springer, 2018.
- [3]. A. H. Haghiahi, A. H. Nasrolahi, and A. Parsaie, *Water quality prediction using machine learning methods*, Water Quality Research Journal, 2018
- [4]. Q. T. Boon, *Secure Water Treatment SWaT*, 2015, <https://itrust.sutd.edu.sg/testbeds/secure-water-treatment-swat/>
- [5]. T. C. Hock, *Water distribution testbed (WADI)*, 2016, <https://itrust.sutd.edu.sg/testbeds/water-distribution-wadi/>
- [6]. F. Muharemi, D. Logofătu and F. Leon, *Machine learning approaches for anomaly detection of water quality on a real-world data set*, Journal of information and telecommunication, 2019
- [7]. G. Sebestyen, A. Hangan, Z. Czako and G. Kovacs, *A taxonomy and platform for anomaly detection*, 2018 IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR), Cluj-Napoca, pp. 1-6, 2018, doi: 10.1109/AQTR.2018.8402710.
- [8]. Z. Czako, G. Sebestyen, and A. Hangan, *Evaluation Platform for Artificial Intelligence Algorithms*, Proceedings of the 10th International Joint Conference on Computational Intelligence (IJCCI), vol. 1, pp. 39-46, 2018, doi: 10.5220/0006888900390046
- [9]. GECCO 2019 Industrial Challenge: *Monitoring of drinking-water quality*, <http://gecco-2017.sigevo.org/index.html/Competitions.html>
- [10]. C. Nitesh, B. Kevin, H. Lawrence, and W. Kegelmeyer, *SMOTE: Synthetic Minority Over-sampling Technique*, Journal of Artificial Intelligence Research (JAIR), vol. 16, pp. 321-357, 2002, 10.1613/jair.953
- [11]. P. Joseph, K. Taghi, D. David, and N. Amri, *Using Random Undersampling to Alleviate Class Imbalance on Tweet Sentiment Data*, pp. 197-202, 2015, 10.1109/IRI.2015.39