

Turbinacsapágy rezgés kiváltó okának feltárása mesterséges intelligenciával

Összefoglalás: Ez a tanulmány a mesterséges intelligencia (MI) gyakorlati alkalmazását mutatja be egy hagyományos erőmű turbinacsapágyának túlzott rezgését kiváltó ok azonosítására. A rezgés évekig szórványosan jelentkezett és a hagyományos diagnosztikai módszerekkel nem tudták meghatározni a turbinatengely ötödik csapágyában fellépő túlzott rezgés okát.

A probléma megoldására egy neurális hálózati programot alkalmaztunk, amely az erőműből származó rendelkezésre álló összes elérhető mérési adatot felhasználta a MI-rendszer betanításához.

A betanítás után a MI kimutatta, hogy a kondenzátor vízszintjével meghatározott sajátfrekvencia, a tengely forgási frekvenciájával kombinálva, volt az esemény tényleges oka.

Kulcsszavak: Mesterséges intelligencia, rezgés a turbinában, neurális hálózati program, forgási frekvencia.

Abstract: This study presents the practical application of artificial intelligence (AI) to identify the cause of excessive vibration in the turbine bearing of a conventional power plant. The vibration had occurred sporadically for years, and conventional diagnostic methods were unable to determine the cause of the excessive vibration in the fifth bearing of the turbine shaft.

To solve the problem, we used a neural network program, which utilized all available measurement data from the power plant to train the AI system. After training, the AI revealed that the natural frequency determined by the condenser's water level, combined with the shaft's rotational frequency, was the actual cause of the event.

Keywords: Artificial intelligence, vibration in the turbine, neural network-program, rotational frequency.

* *Dunaújvárosi Egyetem*

Email: porg@uniduna.hu

ORCID: 0000-0003-1022-5847

Bevezetés


A mesterséges intelligencia (MI) módszereit egyre inkább alkalmazzák az ipari folyamatok matematikai modellezésében. Számos publikáció foglalkozik a neurális hálózati szoftvercsomagok fejlesztésével, mégis kevés jelentés emeli ki ezen technikák sikeres alkalmazását valós ipari problémák megoldásában. Ez a tanulmány egy figyelemre méltó esetet mutat be, ahol a mesterséges intelligenciát sikerrel alkalmaztunk egy hagyományos erőműben régóta fennálló rezgési probléma megoldására.

A probléma évekig fennállt a hagyományos diagnosztikai módszerekkel, beleértve a rezgismérésekkel, számításokkal és végeselemes elemzésekkel végzett ismételt próbálkozások ellenére. Ezen módszerek egyike sem tudta azonosítani a turbinacsapágyak egyikében megfigyelt túlzott rezgéskiváltó okát. A rendszer összetettsége és a fizikai modellek korlátjai miatt a MI-hez fordultunk megoldásért, neurális hálózati technikákat alkalmazva a rendszer viselkedésének modellezésére és a mögöttes ok feltárására.

A probléma leírása

A hagyományos erőmű turbina-generátor rendszerrel működik, amely gyakran különböző gyártók által előállított részekből állnak. Ebben az esetben a turbinát a Brown–Boveri-től, míg a generátort a Ganz-Huslet-től vásárolták. A két alkatrész összekapcsolására kezdetben egy további csapágy nélküli tengelykapcsolót javasoltak, a Brown–Boveri eredeti terve alapján. Mivel azonban az alkatrészek különböző gyártóktól származtak, egy további csapágyat (melyet a továbbiakban t5-nek nevezünk) helyeztek el a tengelykapcsoló közelében (lásd az *1. ábrát*).

1. ábra. A turbina-generátor együttes sematikus ábrázolása. A fő alkatrészek, jelek és csapágyságok megjelölve. A t5-tel jelölt csapágy időnként meg nem engedett rezgést mutatott.



Forrás: Saját ábra.

Normál körülmények között a rendszer komolyabb problémák nélkül működött. Azonban a teljesítménycsökkentések során, amikor az egység teljesítményét kapacitásának körülbelül 50%-ára redukálták, időnként túlzott rezgést figyeltek meg a t5 csapágyban. Ezek a rezgések néha meghaladták a megengedett határértékeket, különösen az egység tehermentesítésekor. A probléma megoldására tett különféle vizsgálatokkal, beleértve a rezgésméréseket, számításokat és végelemes analízist, a rezgéskiváltó okát nem sikerült egyértelműen azonosítani és a nemkívánatos rezgéseket megszüntetni. Gyanították a tengely forgási frekvenciája és a csapágy sajátfrekvenciája közötti rezonanciát, amit tömegek hozzáadásához a csapágy alapjához próbáltak orvosolni. Bár ez kiküszöbölt néhány rezonanciacsúcsot, a tehermentesítés során felépő fajlagos rezgés továbbra is fennállt, és előfordulása következetlen volt, ami még nehezebbé tette a probléma megoldását.


Mivel a probléma okát nem találták meg, úgy döntöttünk, hogy egy mesterséges intelligencia (MI) programot használunk az okok keresésére.

A mért jelek

A modern erőművek számos jelet rögzítenek különböző komponensektől automatizált adatgyűjtő rendszereken segítségével, jellemzően 1–3 másodperces mintavételi gyakorisággal. Ezek a jelek többek között a hőmérsékletet, nyomást, áramlási sebességet, rezgési paramétereket (például sebességet és gyorsulást), tengely excentricitást, energiatermelést és -veszteségeket, olajfogyasztást és csapágyhőmérsékleteket tartalmaznak. Esetünkben az erőmű adatgyűjtő rendszere által rögzített jeleket használtuk egy MI-modell betanításához. A 2. ábra a rögzített adatok tipikus ábrázolását mutatja.

A legfelső jel (világoskék) az energiatermelés változásait mutatja, amelyek reggel 6:30 és 8:30 között 50%-ra csökkentek. Figyelemre méltó, hogy ebben az időszakban két további jel, amelyek a t5 csapágy vízszintes és axiális rezgéseinek felelnek meg (sárga és lila), jelentősen megnőttek és hosszú periódusokkal oszcillálni kezdtek. A rendelkezésre álló adatok bősége ellenére kihívást jelentett a jelek közötti összefüggések azonosítása és ok-okozati összefüggéseik megértése. A hagyományos fizikai modellek már nem voltak elegendőek az ilyen összetett problémák kezeléséhez, és világossá vált, hogy mesterséges intelligenciát alkalmazó matematikai megközelítésre van szükség. Azáltal, hogy egy MI-modellt betanítottunk ezekkel az adatokkal, célunk a túlzott rezgéskiváltó okának feltárása volt.

2. ábra. A betanításhoz használt erőművi adatgyűjtő rendszerből származó jelek.



Forrás: Saját ábra az adatok alapján.

Ennek vizsgálatához két különböző jellekészetet választottunk ki. Az első készlet 12 bemeneti jelet tartalmazott, míg a második készlet 30 bemenetet tartalmazott. A kimenetek kezdetben az 5. csapágy rezgésére korlátozódtak, ami a vizsgálatunk kiindulópontja volt. Később kibővítettük a kimeneteket, hogy több rezgésérzékelőt (akár 7×2 -ig) is tartalmazzon a turbinatengelyen.

A modellezésünkben használt szoftver leírása


Az elemzésünkben használt szoftver, az AiNet [1] egy kereskedelmi forgalomban kapható program, amely shareware termékként érhető el. Bár az AiNet nem egy hagyományos neurális hálózat a szó szoros értelmében, MI-eszközként működik, amely egy mátrixot illeszt a mért adatokhoz [2]. Miután megtalálta az optimális illeszkedést, a modell készen áll a predikciós célokra. A 3. ábra az AiNet grafikus elrendezését mutatja be, amely hasonlóságot mutat más mesterséges neurális hálózatokkal (ANN). Az AiNet két fázisban működik: betanítás (vagy modellezés) és predikció. A betanítási fázisban a modellvektorok (a rögzített adatokból) megjelennek a hálózaton. Ez a folyamat gyors, hasonlóan az adatok megjelenítéséhez más felügyelt neurális hálózatokban, például a valószínűségi neurális hálózatokban (PNN) [3].

[1] Krajnc, A.– Perus, I. (1996): *User Manual AINET Neural Network Software*, Celje: AiNet.

[2] Grabec, I. (1990):: Prediction of a chaotic time series by a self-organising neural network, Dynamic Days, Dusseldorf, 1990.

[3] NEUR (1991): *Neural Computing*, NeuralWare, Inc.

3. ábra. Az aiNet grafikus ábrázolása.



Forrás: A szoftver leírása.

A 3. ábrán látható jelölések jelentése a következő:

- **p** predikciós vektor,
 - **m** modellvektor,
 - **i** a bemeneti változóhoz tartozó neuront jelöli,
 - **o** a kimeneti változóhoz tartozó neuront jelöli.
 - **N** modellvektorok száma,
 - **M** a jelenség bemeneti változóinak száma,
 - **K** a jelenség kimeneti változóinak száma (a bemutatott esetben K egyenlő 1-gyel, és i-t elhagyjuk),
 - **pc** büntetőegyüttható
- n az AiNet esetében.

Az aiNet ANN betanítása (vagy tanulása) a modellvektorok ideghálózaton való betáplálását jelenti. A kapcsolatok súlyai eleinte egygel, vagy nullával egyenlők. A súlyadaptáció kifejezése a következőképpen írható fel:

$$(1) \quad w_{ij} = \bar{w}_{ij} \delta_{kj}$$

Felhívjuk a figyelmet arra, hogy a bemutatott hálózatnak két rejtett rétege van (B-réteg és C-réteg). A B rétegben lévő neuronok száma megegyezik az összes modellvektor N számának és a bemeneti változók számának M szorzatával (N M), míg a C-rétegben lévő neuronok száma a modellvektorok számának kétszerese. Az egyszerűség kedvéért feltételeztük, hogy csak egy kimeneti (ismeretlen) változónk van a D kimeneti rétegben (a későbbi modellekben ezt kettőre emeltük).

A cikk limitált terjedelme nem teszi lehetővé, hogy az AiNet teljes matematikai algoritmusát ismertessük. Az megtalálható az AiNet leírásában. Az ideghálózatban a legfontosabb, hogy mely nódusok nem lineárisak. Ezek a C-rétegben (layerben) találhatók és leírásuk:

$$(2) \quad Y_i^C = f(X_i^C, pc) = e^{\frac{-X_i^C}{pc}}$$

Ez lehetővé teszi az algoritmus betanítását egy előrecsatolt (forward) predikciós módszerrel.


A betanított modellt ellenőrizni kell (validáció). Ehhez a teljes rendelkezésre álló adatmennyiségből félretesszünk kb. 10%-nyi adatot, amelyek nem vesznek részt a betanításban. Azokat az ellenőrzésben használjuk. A betanított modellnek képesnek kell lennie a félretett esetek minél tökéletesebb kiszámítására. Ha a betanított ideghálózati modellszámítás eredménye (bizonyos határon belül) egybeesik a félretett esetekben mért értékekkel, akkor azt gondoljuk, hogy a betanítás sikeres. Egy ilyen példát mutatunk be a következő pontban.

Ezt követi majd a predikciós fázis, ahol a MI-rendszer kiszámítja az ismeretlen kimeneti értékeket predikciós vagy ellenőrzési célokra, biztosítva a modell pontosságát. A predikciós fázis a feldolgozó elemek értékeinek kiszámítását és a predikciós vektor ismeretlen kimeneti értékeinek kiszámítását jelenti (predikció esetén). Vagy a modellvektorok kimeneti értékeit számítja ki (büntető együttható értékének meghatározásához szükséges ellenőrzés szűrése esetén).

A szoftver tesztelése (validálás)

Példaképpen bemutatjuk, hogyan teszteltük az AiNet szoftvert, hogy biztosítsuk annak megbízhatóságát.

4. ábra. 12 bemeneti és 2 kimeneti adattal betanítva az illeszkedés nem volt tökéletes.



Forrás: Saját számítás.


Az első teszt mesterséges adatokkal történt, amelyek lehetővé tették számunkra, hogy felmérjük a szoftver azon képességét, hogy előre jelezze az eredményeket, amikor különböző mennyiségű fehér zajt adtunk az adatokhoz.

Az eredmények azt mutatták, hogy az illesztett modell hatékony volt az előrejelzésekhez, amennyiben az előre jelzett értékek a betanítási adatok tartományán belül maradtak. A betanítási tartományon túli extrapoláció azonban kevésbé pontosnak bizonyult. Ez rávilágított arra, hogy milyen fontos, hogy a MI előrejelzéseit a betanítási adatkészlet határain belül tartsuk, ami számos MI-alapú osztályozási modell, köztük a neurális hálózatok, jól ismert korlátozása.

A 4. ábra már egy korai kísérletet mutat a tanulóadatkészlet illesztésére, a t5 csapágy rezgéseire összpontosítva. A modellt 12 bemeneti és 2 kimeneti jellel (vízszintes és axiális rezgéshez) képeztük ki, 0,15-ös statikus büntető együtthatót alkalmazva. Bár a modell meglehetősen jól illeszkedett a tanulóadatokhoz, a szűrési és verifikációs görbék kissé eltértek, és az oszcillációk eltértek a validációs adatoktól.

A paraméterek finomítása után sokkal jobb illeszkedést értünk el 30 bemeneti és 2 kimeneti jel felhasználásával, 0,15-ös legközelebbi szomszéd büntetőegyütthatóval és normalizált statisztikai modellel (lásd 5. ábra). Ez a modell kiváló egyezést mutatott mind a szűrési, mind az ellenőrző adathalmazokkal, rögzítve mind az amplitúdó növekedését, mind a csökkentett teljesítmény mellett megfigyelt oszcillációkat. Ezzel a modellel magabiztosan tudtunk előre lépni befejezve a betanítási fázist, és elkezdhattuk alkalmazni a MI-modelünk a prediktív elemzéshez.

5. ábra. A modell jó illeszkedését 30 bemenettel és 2 kimenettel érték el 0,15 értékű legközelebbi szomszéd büntetőegyüttható alkalmazásával.




Az adott eset elemzése: Predikció

Miután elértük a modellel való jó illeszkedést, áttértünk a predikciós fázisra. A cél az volt, hogy szimuláljuk, hogyan viselkedne a rendszer bizonyos paraméterek módosítása esetén, ami lehetővé tenné számunkra a túlzott rezgés problémájának lehetséges megoldásainak feltárását.


Az első szimulációnk során a teljesítményt 100%-ról 50%-ra csökkentettük, ahogy az a 6. ábrán látható. Ez tükrözte azokat az üzemi körülményeket, amelyek között a t5 csapágy túlzott rezgése jellemzően előfordult. A betanított MI-modell szerint a túlzott rezgés akkor jelentkezett, amikor a teljesítmény elérte az 50%-ot, ami egyezett a tényleges adatokkal.

6. ábra. A rezgési sebességek változásának előrejelzése különböző teljesítményszintek esetén eredeti adatok felhasználásával



Miután ezt az alapértéket megállapítottuk, elkezdtük szisztematikusan változtatni a bemeneti paramétereket, hogy meghatározzuk azok hatását a rezgésre. Az egyik hipotézis az volt, hogy a t5 csapágy axiális rezgése összefüggésben állhat a kisnyomású turbinaház megnyúlásával. Technikai szempontból ez logikus volt, mivel a turbina megnyúlásának változásai befolyásolhatják a csapágy részét. Amikor azonban a megnyúlás csökkenését szimuláltuk, a t5 csapágy rezgésében nem figyeltünk meg szignifikáns növekedését, amint az a 7. ábrán is látható. Mind a vízszintes, mind az axiális rezgések görbéi majdnem megegyeztek az eredeti adathalmazzal, ami arra engedett következtetni, hogy a megnyúlás nem a túlzott rezgéskiváltó oka.

7. ábra. Az eredeti adatok és a módosított hőmérsékleti adatok felhasználásával kapott előrejelzések összehasonlítása.



Miután számos paramétert korlátozott sikerrel teszteltünk, a legígéretesebb eredményeket a kondenzátor vízszintjének változtatásával érték el. Eredetileg senki nem gondolt arra, hogy ez a paraméter közvetlenül összefügghetne a t5 csapágó túlzott rezgésével, mivel a kondenzátornak nincs közvetlen mechanikai kapcsolata a turbina tengelyével. Mivel azonban az összes bemeneti paraméter változtatható volt az AI-modellen belül, úgy döntöttünk, hogy ezt a paramétert is variáljuk, ezt a hipotézist is teszteljük.

Az eredmények meglepőek voltak. A kondenzátorban egy bizonyos vízszintnél (amely egyébként megfelelt az erőmű leggyakoribb üzemi körülményeinek) megfigyeltük a t5 csapágó túlzott rezgését, amint az a 8. ábrán látható. A vízszint emelésével vagy csökkentésével az AI-modell a rezgés jelentős csökkenését jósolta, így az a nemzeti szabványoknak megfelelően elfogadható határértékeken belül maradt. Bár a csökkenés nem volt hatalmas, elegendő volt ahhoz, hogy a rezgést a megengedett szintre rögzítse.

A MI-modell azonban „nem tudja” ezt, csak „vakon”, mindenre figyelve összefüggéseket keres betanításakor. Ez új perspektívát kínál arra, hogy a látszólag egymással nem összefüggő paraméterek között is összefüggésekre leljünk, amelyek befolyásolhatják a turbina viselkedését.

Ez a MI által vezérelt felfedezés jól szemlélteti a gépi tanulás értékét az ipari alkalmazásokban, ahol az összetett rendszerek számos egymástól függő változóval rendelkeznek. Ebben az esetben a MI-modellünk segített feltárni egy rejtett kapcsolatot, amelyet a hagyományos diagnosztikai módszerekkel önmagában nehéz lett volna kimutatni.

Következtetések

Ez a tanulmány bemutatja a MI lehetőségeit az összetett, régóta fennálló ipari problémák megoldásában. Azáltal, hogy mesterséges intelligenciát alkalmaztunk egy erőműrendszer többváltozós dinamikájának modellezésére, képesek voltunk azonosítani egy turbinacsapágy túlzott rezgésének kiváltó okát, amelyet hiába próbáltak évekig a hagyományos diagnosztikai módszerekkel feltárni.

Az MI sikeresen megtalálta, hogy a kondenzátor sajátfrekvenciája és a turbinatengely forgási frekvenciája közötti rezonancia felelős a rezgésért. A kondenzátorban lévő vízszint beállítása egyszerű, mégis hatékony megoldást kínált a rezonanciafrekvencia eltolásával, így a rezgési amplitúdót elfogadható határokon belülre csökkentve. Ez a felfedezés jól mutatja, hogyan képes a MI feltárni a komplex rendszereken belüli rejtett összefüggéseket, amelyeket a hagyományos megközelítések gyakran figyelmen kívül hagynak. Véleményünk szerint ez a MI-modellek igazi előnye, hogy olyan, a háttérben megbúvó összefüggésekre is fényt tud deríteni, amelyek a berendezés fő csapásának irányába nem esnek bele, nem hívják fel magukra a figyelmet. Ugyanakkor hangsúlyozni szeretnénk, hogy a MI nem gondolkozik, és nem fedez fel új fizikai jelenségeket, csak összefüggéseket valószínűsít. Hiba lenne érthető fizikai magyarázat nélkül elfogadni következtetéseit! Esetünkben, egy olyan kapcsolatra irányította a figyelmet, ami nem volt triviális. De a jelenségnek sikerült rögtön fizikai magyarázatot is adni, ami egyértelműen elfogadhatóvá tette a modellt. Véleményünk szerint nem szabad egy MI-modell predikcióját elfogadni akkor, ha nem lehet értelmes magyarázatot adni az általa feltárt összefüggésekre.

Továbbá a modell sikere rávilágít a változók különböző kombinációival való kísérletezés fontosságára, még azokkal is, amelyek első pillantásra összefüggéstelennek tűnhetnek. Azt is megmutattuk, hogy a betanítás és a validáció milyen fontos az MI alkalmazásában. A modern számítási teljesítménynek köszönhetően az ilyen szimulációk egyre inkább elérhetőek, és az ipari kihívások széles skálájának kezelésére használhatók. Úgy véljük, hogy hasonló MI-alapú modellezési megközelítések alkalmazhatók más, az ipari környezetben régóta fennálló problémákra is.

Köszönetnyilvánítás

Ebben a munkában egy vásárolt AiNet szoftvert használtunk. A problémát J. Vasko vetette fel és részben tesztelte is a diplomamunkájában [4].

[4] Vasko, J. (1998):
Diplomamunka.
Budapest: Budapesti
Műszaki Egyetem.