

Financial Risk&Regulation

Pénzügyi idősorok kezelése szezonalitással

Hírlevél – 2024. október

Az olyan fejlett modellek fontossága, amelyek képesek megmagyarázni és előre jelezni a kulcsfontosságú pénzügyi változókat, mint például a ügyleti kamatlábak, pénzügyi eredmények, volumenek, jövedelmek, az elmúlt években jelentősen nőtt, és várhatóan a jövőben is tovább fog növekedni. Ezek egy speciális típusa, amelyek összetett szezonalitást mutatnak, mint például a napi betétösszegek, tranzakciós volumenek, érdeklődésre tartanak számot a likviditási kockázat és a banki könyvi kamatkockázatának (IRRBB) mérésében és kezelésében. A mögöttes folyamatok megértése lehetővé teszi pontosabb modellek kidolgozását, és hozzáadott értéket teremt a jobb döntéshozatal révén. Ebben a hírlevélben egy gyakorlati példát mutatunk be az írországi betéti és hitelkártyás fizetési adatok felhasználásával. Szélesebb körű kockázatkezelési kontextusért lásd a [2021. szeptemberi ICLAAP](#) és a [2024. áprilisi IRRBB](#) hírleveleket, melyek kapcsolódnak a fent említett témákhoz.

Tipikus kihívások

Napi és napközbeni likviditáskezelés a bankoknál

A bankoknak szembe kell nézniük azzal a kihívással, hogy előre jelezzék a napi és napközbeni betétvolumenek, készpénz be- és -kiáramlások ingadozásait, amelyek kulcsfontosságúak a hatékony likviditáskezelés szempontjából. Fejlett modellek használatával a bankok becsülhetik ezeket a mozgásokat, megragadva az ismétlődő mintákat, mint például a fizetések hatása a betétállományban, hétfégi hatások és szezonális promóciók. A napközbeni likviditási kockázat hatékony kezelése nemcsak a szabályozási megfelelés, hanem a likviditási tartalékok hatékony kihasználása szempontjából is kiemelkedő fontosságú.

Például Magyarországon az ügyfelek betétösszegei egyértelműen felismerhető szezonális mintákat mutatnak. Csak néhány tényezőt megemlítve: 1) a fizetéseket általában a hónap végén vagy

elején utalják át, 2) a nyugdíjakat általában minden hónap 12. naptári napján utalják át¹, 3) a fizetési prémiumokat pedig legtöbbször decemberben, karácsony előtt utalják át.

Jegybanki eszközök hasznosítása

A központi bankok különféle eszközöket kínálnak, mint például a rendelkezésre állást és nyílt piaci műveleteket, hogy segítsék a bankokat a likviditás kezelésében. A pontos szezonális előrejelzések lehetővé teszik a bankok számára, hogy hatékonyabban tervezzék ezen eszközök használatát, egyensúlyba hozva likviditási szükségleteiket és szabályozási követelményeiket.

Például a kötelező tartalékok rendszere havi ciklussal rendelkezik. A bank saját és a bankszektor likviditásának főbb összetevőinek pontosabb előrejelzése magasabb színvonalú információkat nyújthat a megalapozott döntéshozatalhoz.

¹ A 2024-es nyugdíjfelosztás pontos ütemezése a [Magyar Államkincstár honlapján](#) található.)

Kártyaelszámolások előrejelzése

A kártyaelszámolási volumenek pontos előrejelzése elengedhetetlen a pénzügyi intézmények és a fizetésfeldolgozók számára. A bankok modellezhetik a napi és szezonális változásokat a tranzakciós volumenben, amelyet befolyásolnak az ünnepi vásárlások, a különböző akciók és a nyaralási szezonok. Például egy fizetésfeldolgozó előrejelezheti a tranzakciók mennyiségének növekedését a Black Friday és a karácsonyi szezon alatt. Ezeknek a trendeknek az előrejelzésével biztosíthatják a megfelelő feldolgozási kapacitást és likviditást, elkerülve a késedelmeket és növelve az ügyfél-elégedettséget.

Esettanulmány


Felhasznált adatok

A fent leírt kihívásokra megoldást nyújtó technikák bemutatásaként egy olyan adathalmazt elemeztünk, amely az [ír lakosoknak kibocsátott hitel- és](#)

[betéti kártyák napi költési adatait tartalmazza](#).

Az adathalmaz a kártyák napi összes költését és az ATM pénzfelvételeket tartalmazza 2020 márciusától 2022 augusztusáig. Ez az időszak számos érdekes jelenséget mutat, például heti, havi és éves szezonális mintázatot, meglepő viselkedést húsvétkor és más ünnepeken, valamint egy általános trendet, mely a teljes értékesítési forgalomhoz kötődik, amit a COVID is befolyásolt. Az idősor az 1. ábrán látható.

Az elemzés során külső magyarázó változóként használtuk a [havi kiskereskedelmi összesített értékesítési indexet](#). Azonban ennek az adatsornak a gyakorisága alacsonyabb, mint a függő változóé, ezért magasabb frekvenciára transzformáltuk át. Az eltérő frekvenciájú idősorok összehangolására vannak bonyolult módszerek, melyek biztosítják, hogy a kapott magas frekvenciájú sorozat összege, átlaga, első vagy utolsó értéke megegyezzen az eredeti alacsony gyakoriságú adatokkal.



1. ábra

A hitel- és betéti kártyás költések idősora, a fekete szakasz jelzi a tanuló adathalmazt, a kék pedig a teszt-adathalmazt.

Használt modellek

Naiv megközelítés

A naiv megközelítések egyszerű, de hatékony szabályt kínálnak a jövőbeli előrejelzések generálására, és alapot biztosítanak az összetettebb modellek összehasonlításához. Az egyszerű naiv modell a legutóbbi adatpontot használja az összes jövőbeli előrejelzéshez, de ez a legutóbbi adatok iránti elfogultsághoz vezet. Ezzel szemben a szezonális naiv modell javít ezen azáltal, hogy az utolsó megfigyelt értéket használja az előző időszakból, például az előző hét pénteki értékesítéseit használja a következő hét pénteki értékesítéseinek előrejelzéséhez.

Szezonális Autoregresszív Integrált Mozgóátlag (Seasonal Autoregressive Integrated Moving Average ~ SARIMA) modell

Az összetettebb modellekhez több magyarázó változót használtunk. Az elemzésünkbe beépítettük a szezonális változásokat, beleértve a heti, havi és éves mintázatokat, egy speciális szezonális funkciócsalád segítségével. Ezenkívül különböző dummy változókat vezettünk be az ünnepek, például a karácsony és az ír ünnepek, mint például március 17. (Szent Patrik napja) során előforduló kiugró értékek figyelembevételére. A trendet több lineáris szegmens segítségével építettük fel, amelyek mindegyike az adott negyedév trendjét képviseli. Mielőtt a modellt előrejelzésre használtuk volna, biztosítottuk, hogy az idősor stacionárius legyen, eltávolítva minden trendet vagy szezonális differenciálással, beleértve a szezonális differenciálást is, amikor szükséges volt. A SARIMA modell előnyei közé tartozik a rövid távú előrejelzés hatékonysága kizárólag historikus adatok felhasználásával, valamint a stacionárius adatok hatékony kezelése. Azonban ezen modellek gyengébb teljesítményt nyújtanak a hosszú távú előrejelzéseknél, nehezen jelzik előre a fordulópontokat, nagyobb a számítási igényük és szubjektív a paraméterválasztásuk.

Idősoros lineáris modell (Time series linear model ~ TSLM)

Ezek a modellek trend és szezonális komponensek segítségével illesztenek lineáris modellt idősorokra. Amikor egy késleltetett komponens is hozzáadtunk az adatokhoz, még jobb eredményeket értünk el. Emellett szakaszonkénti lineáris trendet, speciális szezonális kezelő funkciócsaládot és külső változót is használtunk, hasonlóan a SARIMA modellhez.

Neurális háló autoregresszió (Neural network autoregression ~ NNAR) modell

Az NNAR modellek egy idősor késleltetett értékeit használják bemenetként egy neurális háló keretében. Ez a megközelítés hasonló a hagyományos autoregresszióhoz, de rejtett rétegeken keresztül egy nemlineáris adatfeldolgozást alkalmaz. Az NNAR modell tartalmazhat nem szezonális és szezonális bemeneteket is, a konfigurációkat a késleltetett megfigyelések száma és a rejtett réteg neuronainak száma jelzi.

Prophet modell

A [Prophet modellt a Facebook fejlesztette ki](#), és olyan idősor adatok előrejelzésére tervezték, amelyek erős szezonális mintázatokat mutatnak és amiket ünnepek befolyásolnak. Ez egy nemlineáris regressziós modellként működik, amely szakaszonkénti lineáris trendet, szezonális ingadozásokat és dummy változókkal reprezentált ünnepi hatásokat tartalmaz. Ez a modell különösen hatékony többéves napi adatok esetén, és egy Bayes-i keretrendszert használ a rugalmas modellillesztéshez és a trendváltozások és egyéb paraméterek automatikus meghatározásához.


Kombináció

Az előrejelzési pontosság javítása érdekében a különböző előrejelzéseket kombinálhatjuk. [Sokszor megfigyelt jelenség](#), hogy az egyes modellek előrejelzéseinek összesítésével a kombinált előrejelzések gyakran jobb eredményeket érhetnek el, mint bármely egyedi modell önmagában. A kombinációt az általunk használt többi modell egyszerű számtani átlagaként határoztuk meg.

Az eredmények értékelése

Képzési és tesztadatkészletek

A 2020 márciusától 2022 júliusáig terjedő adatokat használtuk a tanuló adathalmazként, míg a fennmaradó hónapot, 2022 augusztusát, a tesztadathalmazként. A tanuló adathalmazt a modellünk betanítására használtuk, míg a tesztadathalmazt a teljesítményének értékelésére. Ez a megközelítés azt méri, hogy a modellünk mennyire jól teljesít a nem látott adatokon, és segít azonosítani az esetleges problémákat, például a túltanulást. Elemzésünk csak bemutatási célokat szolgál, nem átfogó. Nem használható az idősorok vagy modellek értékelésére, illetve előrejelzések készítésére valós üzleti környezetben.



2. ábra

Előrejelzések a teszt adathalmazon

Metrikák

Az alábbi előrejelzési pontossági metrikákat alkalmaztuk a modellek értékelésére az előrejelzett értékek és a tényleges megfigyelések összehasonlításával. A Mean Error (ME) a modell torzítását értékeli, míg a Root Mean Square Error (RMSE) és a Mean Absolute Error (MAE) a hibák nagyságát számszerűsíti, az RMSE érzékenyebb a nagy hibákra a reziduálisok négyzetre emelése miatt. A Mean Absolute Percentage Error (MAPE) és a Mean Percentage Error (MPE) a hibákat a tényleges értékek százalékában fejezi ki, ami intuitívvá teszi őket az üzleti alkalmazások számára. További metrikák, mint a Mean Absolute Scaled Error (MASE) és a Root Mean Square Scaled Error (RMSSE) méretfüggetlen hibák összehasonlítását biztosítják, és az előrejelzési hibák első autokorrelációja (ACF1) a maradékokban lévő mintázatokat észleli, amelyek modellhiányosságokra utalhatnak.

Eredmények

A teljesítménymetrikák eredményei az 1. táblázatban találhatóak meg a tanulási adathalmazra, és a 2. táblázatban a tesztadathalmazra. Az eredmények vizuálisan a 2. ábrán láthatóak. Referenciaként a SNAIVE megközelítés teljesítménymetrikáit is kiszámítottuk. Ez egy alapvető előrejelzési megközelítés, ami példánkban a Prophet modell kivételével mind jobban tudtak teljesíteni nála.

A tanulási adathalmazon a legjobban teljesítő modell az NNETAR a legtöbb metrika alapján, azonban ez a modell a tesztadatokban csak átlagos teljesítményt nyújt, tipikus példája a túltanulásnak.

A tesztadathalmazon a (késleltetett) TSLM nyújtja a legjobb teljesítményt az elsőrendű autokorrelációt kivéve az összes metrika esetében. Ez arra utal, hogy lehetnek kiaknázatlan mintázatok. A modell sokkal jobb eredményt ér el, mint a SNAIVE megközelítés, amely a referencia-előrejelzésnek számít.

| Model | Type | ME Mean Error | RMSE Root Mean Square Error | MAE Mean Absolute Error | MPE Mean Percentage Error | MAPE Mean Absolute Percentage Error | ACF1 1st order auto-correlation |
|--------------------|----------|------------------|--------------------------------|----------------------------|------------------------------|--|------------------------------------|
| Combined | Training | 641.46 | 15381.09 | 9153.36 | -0.61 | 4.77 | 0.47 |
| TSLM (with lag) | Training | 511.13 | 14624.24 | 9439.11 | -0.32 | 4.76 | 0.07 |
| TSLM (without lag) | Training | 676.19 | 18423.46 | 11937.52 | -0.45 | 5.90 | 0.49 |
| NNETAR | Training | 400.47 | 7809.49 | 4810.78 | -0.05 | 2.17 | 0.06 |
| Prophet | Training | 6.05 | 18376.19 | 11582.86 | -0.77 | 5.97 | 0.47 |
| SARIMAX | Training | 836.13 | 15823.76 | 9872.21 | -0.37 | 5.22 | 0.00 |
| SNAIVE | Training | 577.51 | 33870.81 | 18553.44 | -1.89 | 10.23 | 0.61 |

1. táblázat: Teljesítménymetrikák a tanulási adathalmazon

| Model | Type | ME Mean Error | RMSE Root Mean Square Error | MAE Mean Absolute Error | MPE Mean Percentage Error | MAPE Mean Absolute Percentage Error | ACF1 1st order auto-correlation |
|--------------------|------|------------------|--------------------------------|----------------------------|------------------------------|--|------------------------------------|
| Combined | Test | -8319.84 | 17864.61 | 13899.89 | -3.45 | 5.54 | 0.26 |
| TSLM (with lag) | Test | 244.75 | 15989.90 | 10461.09 | -0.03 | 4.20 | 0.28 |
| TSLM (without lag) | Test | -46.44 | 17514.31 | 11852.77 | -0.20 | 4.64 | 0.37 |
| NNETAR | Test | -8491.86 | 16828.46 | 12570.68 | -3.38 | 4.94 | 0.09 |
| Prophet | Test | -12870.67 | 30317.57 | 23948.79 | -5.59 | 9.58 | 0.24 |
| SARIMAX | Test | -13468.09 | 19967.65 | 17348.88 | -5.57 | 7.00 | 0.30 |
| SNAIVE | Test | -15286.72 | 23022.96 | 19844.68 | -5.92 | 7.65 | 0.32 |

2. táblázat: Teljesítménymetrikák a tesztadathalmazon



További lépések a való életben

A hosszúsági korlátok miatt itt zárjuk hírlevelünket, de megjegyezzük, hogy a gyakorlatban egy modellfejlesztési folyamat további lépéseket igényelne az adatok generálási folyamatának átfogóbb elemzéséhez és részletesebb megértéséhez. Például az Idősorelemzési Keresztvalidáció (Time Series Cross-Validation ~ TSCV) egy robusztus technika az idősorok elemzésében használt

modellek értékelésére, biztosítva, hogy a megfigyelések időbeli sorrendje megmaradjon. A hagyományos keresztvalidációval ellentétben, amely véletlenszerű adatfelosztásokat használ, a TSCV megőrzi a megfigyelések időbeli sorrendjét, a múltbeli adatokon tanít és a jövőbeli adatokon tesztel, hogy valós világ forgatókönyveit szimulálja. Ez a módszer segít annak értékelésében, hogy a modell stabil kimeneteket produkál-e időben, vagy sem.

A hírlevelet készítette: Soltész József, K. Nagy Judit, Székely György.

Kontakt:



Rakó Ágnes
Partner
M: +36 70 370 1792
E: agnes.rako@kpmg.hu
[KPMG.hu](https://www.kpmg.hu)



Szalai Péter
Associate Partner
M: +36 70 370 1739
E: peter.szalai@kpmg.hu



Soltész József
Szenior Menedzser
M: +36 70 370 1766
E: jozsef.soltesz@kpmg.hu



A jelen dokumentumban ismertetett szolgáltatások közül néhány vagy mindegyik lehet, hogy nem engedélyezett a KPMG könyvvizsgálattal érintett ügyfelei, valamint azok leányvállalatai vagy kapcsolt társaságai esetében.

A jelen dokumentumban lévő információk általános jellegűek, és nem vonatkoznak egyetlen konkrét személy vagy társaság körülményeire sem. Bár törekszünk arra, hogy pontos és időszzerű információkat adjunk, nem lehet garancia arra, hogy ezek az információk pontosak abban az időpontban, amikor megkapják azokat vagy arra, hogy pontosak maradnak a jövőben. Az ilyen információk alapján senkinek sem szabad intézkedéseket hozni megfelelő szakmai tanácsadás nélkül az adott helyzet alapos felmérését követően.

© 2024 KPMG Tanácsadó Kft., a magyar jog alapján bejegyzett korlátolt felelősségű társaság, és egyben a KPMG International Limited („KPMG International”) angol „private company limited by guarantee” társasághoz kapcsolódó független tagtársaságokból álló KPMG globális szervezet tagtársasága. Minden jog fenntartva.

A KPMG név és logó a KPMG globális szervezet független tagtársaságai által licenc alapján használt védjegyek.