

HELYETTESÍTŐ MODELL ALAPÚ OPTIMALIZÁLÁS TERMELÉSI RENDSZEREK FEJLESZTÉSÉRE

SURROGATE MODEL-BASED OPTIMIZATION FOR THE DEVELOPMENT OF PRODUCTION SYSTEMS

Ruzicska Gábor*, Dr. Czégé Levente**, Dr. Mankovits Tamás***

ABSTRACT

Optimizing production systems using simulation models makes it possible to analyze system performance under various operating conditions; however, running simulation experiments multiple times can require significant computational resources. The goal of this research is to develop and evaluate an approach for optimizing a manufacturing system based on a surrogate model, and then to validate the resulting solution using the original simulation model. The subject of this study is a stochastic production system in which the speeds of the two conveyor belts and the processing time spent at the production station serve as control parameters. The system's efficiency is evaluated based on three indicators: productivity, average congestion time, and equipment downtime. Based on the data obtained from the simulation experiments, we construct surrogate models that approximately describe the relationship between the control parameters and the system's performance metrics. To find the optimal combination of parameters, a genetic algorithm is used that relies on the predictions of the surrogate model at each step of the optimization process, rather than running the simulation model directly. The resulting optimal configuration is subjected to further validation using the original simulation model. Given the stochastic nature of the system under study, validation is performed using multiple independent iterations, which allows for the evaluation of the mean values of the performance metrics and their standard deviations. The results of the research indicate that the use of surrogate models is a promising solution for reducing computation time in the optimization of manufacturing systems, while repeated simulation validation makes it possible to assess the reliability of the resulting optimal solution.

1. BEVEZETÉS

A modern gyártási rendszereket az egyes technológiai folyamatok nagyfokú összetettsége és egymástól való függése jellemzi. A berendezések paramétereinek, a szállítási műveleteknek és a feldolgozási időnek a megváltoztatása jelentősen befolyásolhatja a teljes rendszer teljesítményét. Ezért a leghatékonyabb üzemmód meghatározása fontos feladat a termelési

rendszerek tervezése és fejlesztése során. A gyártási rendszerek vizsgálatának egyik elterjedt módszere a diszkrét eseményalapú szimulációs modellezés. A szimulációs modellek lehetővé teszik a technológiai műveletek sorrendjének, a gyártási erőforrások korlátainak, a munkállomások közötti termékfelhalmozódásnak, valamint például a berendezések meghibásodásával kapcsolatos véletlenszerű események figyelembevételét. Az analitikai modellektől eltérően a szimulációs modellezés lehetővé teszi a bonyolult gyártási folyamatok vizsgálatát anélkül, hogy azok szerkezetét jelentősen le kellene egyszerűsíteni. Ugyanakkor a szimulációs modellek közvetlen alkalmazása az optimalizálási folyamat során jelentős számításiigénnyel járhat, mivel a paraméterek minden egyes kombinációjának értékeléséhez külön szimulációs kísérletet kell elvégezni. Ez a probléma különösen aktuális a sztochasztikus gyártási rendszerek esetében. Ebben az esetben ugyanaz a bemeneti paraméterkészlet véletlenszerű tényezők jelenléte miatt eltérő eredményeket eredményezhet a modell egyes futtatásai során. A teljesítmény megbízható becsléséhez több független ismételtség végrehajtására van szükség, ami tovább növeli az optimalizálási eljárás számítási igényét. Így olyan módszerekre van szükség, amelyek lehetővé teszik a szimulációs modellhez intézett közvetlen lekérdezések számának csökkentését anélkül, hogy a vizsgált rendszer becslésének pontossága jelentősen romlana. Az egyik lehetséges megoldás a helyettesítő modellek alkalmazása. Ez a megközelítés egy számításiigényben alacsony költségű közelítő modell felépítését jelenti, amely a korábban elvégzett szimulációs kísérletek eredményein alapul. A betanítás után a helyettesítő modell felhasználható a gyártási rendszer kimeneti jellemzőinek gyors előrejelzésére a bemeneti paraméterek különböző kombinációi esetén. Ez lehetővé teszi, hogy a számítási terhelés nagy részét a szimulációs modellel a lényegesen gyorsabb előrejelzési szakaszra helyezzük át, és a kapott modellt közvetlenül az optimalizálási eljárásban használjuk fel. A gépi tanulási módszerek különösen érdekesek a helyettesítő modellek felépítéséhez, mivel képesek a bemeneti és kimeneti változók közötti nemlineáris összefüggéseket közelíteni. Különösen a döntési fákra épülő módszerek alkalmazhatók a gyártási rendszerekben felmerülő összetett összefüggések modellezésére. Azonban az

* tanársegéd, Debreceni Egyetem Műszaki Kar, Gépészmérnöki Tanszék

** egyetemi docens, Debreceni Egyetem Műszaki Kar, Gépészmérnöki Tanszék

*** egyetemi docens, Debreceni Egyetem Műszaki Kar, Gépészmérnöki Tanszék

egyes helyettesítő modellek magas pontossága nem garantálja, hogy az azok segítségével megtalált optimális konfiguráció hasonló jellemzőket biztosít majd a kiindulási sztochasztikus szimulációs modell újbóli futtatásakor. Ezért a helyettesítőmodell-alapú optimalizálás fontos eleme a kapott megoldás független ellenőrzése a kiindulási modell segítségével. Jelen tanulmányban egy olyan megközelítést vizsgálunk a sztochasztikus termelési rendszer optimalizálására, amelyben a helyettesítőmodellt használjuk a vezérlőparaméterek optimális kombinációjának megtalálásához, majd a kapott megoldást egy diszkrét eseményalapú szimulációs modell segítségével ellenőrizzük. A vezérlő paraméterekként a két szállítószalag sebességét és a gyártóállomáson eltöltött feldolgozási időt vesszük figyelembe. A rendszer hatékonyságának kritériumai a termelékenység, az átlagos torlódási idő és a berendezés meghibásodási ideje. Az optimális konfiguráció megtalálásához genetikus algoritmust alkalmazunk, amely a helyettesítő modellekből származó, előre jelzett mutatóértékeket használ fel. A kutatás fő célja annak értékelése, hogy alkalmazható-e a helyettesítő-alapú optimalizálás a sztochasztikus gyártási rendszer hatékony működési üzemmódjának meghatározására, valamint a kapott megoldás megbízhatóságának ellenőrzése többszöri, egymástól független szimulációs ismétlések segítségével. Ez a megközelítés nemcsak a jövőbeni gyártási paraméterek ígéretes kombinációjának meghatározását teszi lehetővé, hanem a helyettesítő modell előrejelzései és a kiindulási szimulációs modell tényleges eredményei közötti eltérések számszerű értékelését is. A kizárólag a gépi tanulási modell pontosságának értékelésére irányuló kutatásokkal ellentétben a jelen tanulmányban a fő hangsúlyt a helyettesítő modellnek az optimalizációs folyamat részeként való felhasználására, valamint a megtalált megoldás utólagos statisztikai validációjára helyezzük. Ez lehetővé teszi, hogy a helyettesítő modellt ne csupán előrejelzési eszközként, hanem a termelési rendszer szimulációs-optimalizációs vizsgálatának hatékonyságát növelő eszközként is tekintsük.

2. IRODALOMKUTATÁS

A szimulációs modellezést széles körben alkalmazzák összetett gyártási rendszerek elemzésére és optimalizálására; azonban a számításgépes modellek közvetlen felhasználása az optimalizálási eljárásokban jelentősen megnövelheti a megoldás kereséséhez szükséges időt. Ennek kapcsán a szakirodalomban jelentős figyelmet szentelnek a metamodelleknek és a helyettesítő modelleknek, amelyek közelítőleg leírják a rendszer bemeneti paraméterei és a szimulációs modellezés eredményei közötti összefüggést [1].

Barton és Meckesheimer a metamodellt a szimulációs modellezésen alapuló hatékony optimalizációs eszközként tekintik. A szerzők rámutatnak, hogy a metamodell alkalmazásával a kiindulási modell számos

költséges futtatása helyett lényegesen gyorsabb számítások végezhetők, ami különösen fontos a sztochasztikus diszkrét eseményalapú rendszerek esetében [2].

Hong és Zhang áttekintése a sztochasztikus szimulációs modellek helyettesítő optimalizálásának modern módszereivel foglalkozik. A szerzők különböző típusú helyettesítő modelleket vizsgálnak, és hangsúlyozzák a válaszfelület-aproximáció és az optimumkeresési eljárás hatékony kombinációjának fontosságát [3].

Ezen irányzat szisztematikusabb elemzését a metamodell-alapú szimulációs optimalizálásról szóló tanulmány tartalmazza. A szerzők osztályozzák a meglévő megközelítéseket, és rámutatnak arra, hogy a gépi tanulási módszerek fejlődése további lehetőségeket teremt a komplex szimulációs rendszerek rugalmasabb és pontosabb metamodelljeinek kidolgozásához [4].

Különösen aktuális a metamodellek közvetlen alkalmazása a gyártási rendszerekben. Li és munkatársai kidolgoztak egy metamodellt egy sztochasztikus gyártási rendszerhez, és integrálták azt a Monte Carlo-módszerrel, valamint a gyártástervezés többkritériumos optimalizálásával. Az eredmények azt mutatták, hogy jelentősen felgyorsítható az alternatív gyártási megoldások értékelése [5].

Hasonló irányvonalat mutat be az a tanulmány, amely a gyártási mutatók többcélú optimalizálását vizsgálja egy diszkrét eseményalapú gyártási modell helyettesítőmodellje alapján. A szerzők metamodellt alkalmaztak több gyártási kritérium közelítésére, majd egy kompromisszumos megoldás keresésére. Ez alátámasztja a szurrogátmodellek alkalmazásának célszerűségét, amikor a gyártási rendszer több jellemzőjét is egyszerre kell figyelembe venni [6].

Egy külön irányzat a Random Forest paraméteres helyettesítő modellként való alkalmazásához kapcsolódik. Antoniadis és munkatársai kimutatták, hogy a Random Forest hatékonyan felhasználható metamodellek felépítésére, valamint a bemeneti változók komplex modellek eredményeire gyakorolt hatásának értékelésére. Jelen kutatás szempontjából különösen fontos, hogy a jellemzők fontossági mutatói felhasználhatók a rendszer érzékenységi elemzéséhez [7].

A gépi tanulási módszerek kiválasztásának és beállításának kérdése szintén jelentős szerepet játszik. A helyettesítő modellezési feladatokban különböző gépi tanulási algoritmusokat összehasonlító kutatások azt mutatják, hogy a modellek hatékonysága a paraméterter szerkezetétől és a kiindulási adatok jellemzőitől függ. Ezért egy adott algoritmus kiválasztásakor figyelembe kell venni a vizsgált gyártási rendszer sajátosságait és a rendelkezésre álló adathalmazt.

Korábbi kutatásokban a metamodellezést már közvetlenül a gyártási rendszerek tervezéséhez is alkalmazták. Például a neurális hálózatok és a sztochasztikus lokális keresés együttes használata lehetővé tette a gyártási rendszer optimalizálását anélkül,

hogy folyamatosan vissza kellett volna térni a kiindulási szimulációs modellhez [8].

Így a szakirodalom elemzése azt mutatja, hogy a helyettesítő modellezés ígéretes eszköz a komplex gyártási rendszerek optimalizálásának felgyorsításához. Ugyanakkor a kutatások többsége vagy a pontos metamodellek felépítésére, vagy az optimalizálási algoritmusok kidolgozására összpontosít. Jelen tanulmányban a közvetlen integrációjukra helyezzük a hangsúlyt: a Random Forest modellt gyors helyettesítőként használjuk a genetikus algoritmuson belüli szimulációs modell helyett, majd a megtalált optimális megoldást független futtatásokkal az eredeti sztochasztikus modell segítségével további ellenőrzésnek vetjük alá. Ez a megközelítés lehetővé teszi az optimalizációs keresés hatékonyságának és a megtalált megoldás gyakorlati alkalmazásának egyidejű értékelését.

3. MÓDSZERTAN

Jelen tanulmányban egy gyártási rendszer optimalizálására szolgáló módszertant javasunk, amely a diszkrét eseményalapú szimulációs modellezés, a helyettesítő modell és az optimalizációs algoritmus együttes alkalmazásán alapul.

Először egy szimulációs modell segítségével létrehozunk egy adatsort, amely a gyártási rendszer működésének eredményeit tartalmazza a vezérlő paraméterek különböző kombinációi esetén. A kapott adatok alapján betanítjuk a helyettesítő modelleket, amelyek lehetővé teszik a főbb teljesítménymutatók értékelését anélkül, hogy közvetlenül elindítanánk az eredeti szimulációs modellt. A helyettesítő modellek pontosságának értékelését követően azokat számításgényes értékelési függvényként használják az optimalizációs algoritmuson belül. A megtalált optimális konfigurációt ezután visszajuttatják az eredeti szimulációs modellbe, és több független ismétlés segítségével ellenőrzik.


A javasolt megközelítés a következő fő lépésekből áll:

1. adatbázis létrehozása szimulációs modell alkalmazásával;
2. az adatok előfeldolgozása és előkészítése;
3. helyettesítő modellek felépítése és értékelése;
4. az optimalizálási célfüggvény meghatározása;
5. a vezérlő paraméterek optimális kombinációjának keresése;
6. a kapott megoldás független validálása a kiindulási szimulációs modell felhasználásával.

Ez a felosztás lehetővé teszi, hogy az közelítő modell felépítésének szakaszát elkülönítsük az optimalizálás és a talált megoldás utólagos ellenőrzésének szakaszától.

3.1. Szimulációs modell és vezérlő paraméterek

A kutatás tárgyát a Siemens Tecnomatix Plant Simulation szoftverkörnyezetben megvalósított gyártási rendszer képezi. A modell a gyártási folyamat diszkrét eseményalapú modellje, amely magában foglalja a termékek szállítását a technológiai műveletek között, valamint a termékek feldolgozását a gyártóállomáson. Az 1. ábra szemlélteti a modell sematikus ábráját.



1. ábra A gyártási rendszer sematikus ábrája

Három változót veszünk figyelembe vezérlő paraméterként:

$$\theta = [v_1, v_2, p_i] \quad (1)$$

ahol v_1 és v_2 a két szállítószalag sebessége, illetve p_i az állomás feldolgozási ideje.

A szimulációs modell minden paraméterkombinációra kiszámítja a rendszer teljesítményét jellemző kimeneti mutatók értékeit. Jelen tanulmányban három fő mutatót használunk:

- Kapacitás (T) - a rendszer által a vizsgált időszak alatt előállított termékek száma;
- Átlagos torlódási idő (C) - a rendszer vizsgált elemeiben fellépő torlódások átlagos időtartama;
- Meghibásodási idő (F) - a berendezések meghibásodásainak időtartama.

Így a vezérlő paraméterek és a termelési rendszer jellemzői közötti összefüggés általános formában a következőképpen ábrázolható:

$$Y(\theta, \zeta) = [T(\theta, \zeta), C(\theta, \zeta), F(\theta, \zeta)] \quad (2)$$

ahol ζ a szimulációs modellben jelen lévő véletlenszerű tényezőket jelöli, melyek jelenléte teszi a feladatot sztochasztikussá, azaz azonos vezérlőparaméterek mellett a modell egyes futtatásai eltérhetnek.

3.2. Adatok előkészítése a helyettesítő modellhez

A helyettesítő modell felépítéséhez a szimulációs kísérletek eredményeként kapott adatsort használjuk fel. Az adatsor minden egyes sora egy bemeneti paraméterkombinációnak és a hozzá tartozó szimulációs modell futtatásának eredményeinek felel meg. A létrehozott adatkészlet 40000 megfigyelést tartalmaz. A vizsgált paramétertartomány

$$\begin{aligned} 0.01 \leq v_1 \leq 0.3 \\ 0.01 \leq v_2 \leq 0.3 \\ 20 \leq p_t \leq 60 \end{aligned} \quad (3)$$

3.3. A helyettesítő modell felépítése

A vezérlő paraméterek és a teljesítménymutatók közötti összefüggések közelítéséhez a véletlenszerű erdő (Random Forest) módszert alkalmazzuk. A három kimeneti mutató mindegyikéhez külön regressziós modellt építünk:

$$\begin{aligned} \hat{T} &= f_T(v_1, v_2, p_t) \\ \hat{C} &= f_C(v_1, v_2, p_t) \\ \hat{F} &= f_F(v_1, v_2, p_t) \end{aligned} \quad (4)$$

ahol $\hat{T}$, $\hat{C}$ és $\hat{F}$ a helyettesítő modell előrejelzései.

A kiindulási adathalmazt tanulási és tesztelési részre osztjuk. Az tanulási mintát a modellek felépítéséhez használjuk, míg a tesztelési mintát a modellek prediktív képességének független értékelésére alkalmazzuk. Értékelési kritériumként a négyzetes középértékű hiba (RMSE), az átlagos abszolút hiba (MAE) és a determinációs együttható R^2 szolgálnak.

1. táblázat A modell adatai

	Kapacitás	Átlagos torlódási idő	Meghibásodási idő
RMSE	2.649	1.705	125.001
MAE	1.829	1.318	95.385
R^2	0.985	0.975	0.921

A helyettesítő modell további alkalmazásának fontos feltétele az optimalizálás során az, hogy a modell képes legyen kellő pontossággal leképezni a bemeneti és kimeneti paraméterek közötti összefüggést. Ezért a modellek értékelésének szakaszát az optimalizálási eljárás megkezdése előtt hajtjuk végre.

3.4 A célfüggvény definiálása

Mivel egyszerre kell növelni a termelékenységet, és csökkenteni a torlódások és a meghibásodások előfordulási idejét, a feladat természeténél fogva többkritériumosnak tekinthető. Az egykritériumos

optimalizációs algoritmus alkalmazásához a három mutatót egyetlen normalizált célfüggvénybe egyesítjük.

A normalizált mutatók a rendszer alapüzem módjához viszonyítva határozhatók meg:

$$\begin{aligned} T_n &= \frac{\hat{T}}{T_0} \\ C_n &= \frac{\hat{C}}{C_0} \\ F_n &= \frac{\hat{F}}{F_0} \end{aligned} \quad (5)$$

ahol T_0 , C_0 és F_0 a rendszer alapkonfigurációjában szereplő mutatóértékek.

A célfüggvény a következő formájú:

$$J(\theta) = w_T(1 - T_n) + w_F F_n + w_C C_n \quad (6)$$

ahol $w_T=1$, $w_C=0.5$ és $w_F=0.3$ a célfüggvényben alkalmazott súlyértékek.

Ebben a megfogalmazásban a T növelése az első tag csökkenéséhez vezet, míg az F vagy a C növelése a célfüggvény értékét növeli. Ezért az optimalizálási feladat a következőképpen fogalmazható meg [6]:

$$\theta^* = \arg \min J(\theta) \quad (7)$$

3.5 Helyettesítő modell-alapú optimalizálás

Az optimális paraméterkombináció megtalálásához genetikus algoritmust alkalmazunk. A szimulációs modellen alapuló közvetlen optimalizálástól eltérően az algoritmus minden iteráció során egy számításigényesebb helyettesítő modellt vesz igénybe.

Minden lehetséges kombináció esetében a

$$\theta_i = [v_{1,i}, v_{2,i}, p_{t,i}] \quad (8)$$

helyettesítő modellek kiszámítják a következő előrejelzett értékeket. Ezen értékek alapján meghatározhatók a $J(\theta_i)$ értékek. A genetikus algoritmus a kapott célfüggvény-értéket használja fel új jelölt megoldások kiválasztására és kialakítására.

3.6 Az optimális megoldás szimulációs validációja


A folyamat során kapott eredményt nem tekintjük automatikusan végleges optimális megoldásnak, mivel a helyettesítő modell csak közelíti az eredeti rendszert.

Ezért az optimalizálási eredmény validálása az eredeti Plant Simulation modellen történik. Az optimális paraméterkombináció mellett r egymástól független

szimulációs replikációt végzünk. A validáció során a surrogate modell által előre jelzett értékeket összehasonlítjuk az eredeti szimulációs modell több független futtatásából származó átlagos értékekkel. Emellett meghatározható a relatív eltérés.

4. EREDMÉNYEK

Az optimalizálást genetikus algoritmus segítségével hajtottuk végre. Az optimalizálás során a célfüggvény értékének gyors csökkenése volt megfigyelhető. Már az első generációban a legjobb érték 0,6586 volt, a hetedik generációra pedig 0,6451-re csökkent. Ezt követően a célfüggvény értékének további javulása gyakorlatilag nem volt megfigyelhető.



2. ábra A célfüggvény konvergenciája az optimalizálás során

A kapott optimális megoldást a következő vezérlőparaméter-értékek jellemzik:

2. táblázat Az optimalizálás eredménye

Paraméter	Optimális Érték
1.szállítószalag sebessége	0.0118 [m/s]
2.szállítószalag sebessége	0.1788 [m/s]
Fordító állomás feldolgozási ideje	40.3213 [s]

A helyettesítő modellek előrejelzései szerint a megadott paraméterek mellett a termelési rendszer várható jellemzői a következők:

3. táblázat Az optimális értékek előrejelzései

Mutató	Előrejelzett érték
Kapacitás	211.47 [db]
Átlagos torlódási idő	104.67 [s]
Meghibásodási idő	810.58 [s]

Így a helyettesítő modelleken alapuló genetikus algoritmus meghatározta azt a paramétertartományt,

amelyben kompromisszum jön létre a rendszer teljesítménye, a termékek felhalmozódásának mértéke és a berendezés megbízhatósága között.

Különös figyelmet érdemel az optimalizációs folyamat konvergenciájának jellege. A célfüggvény értéke az első generációban mért 0,6586-ról a hetedik generációban 0,6451-re csökkent, majd az algoritmus befejezéséig gyakorlatilag változatlan maradt. Ez arra utal, hogy a felépített helyettesítő modell keretein belül a talált megoldás stabil a genetikus algoritmus további keresése tekintetében.

4.1 Az optimális megoldás validációja

Mivel az optimalizálás nem közvetlenül a szimulációs modellen, hanem annak helyettesítő modelljén történt, a kapott megoldást a termelési rendszer eredeti modelljének felhasználásával további ellenőrzésnek kell alávetni.

Ehhez a megtalált paraméterkészlet:

- $v_1=0.0118$ [m/s]
- $v_2=0.1788$ [m/s]
- $p_t=40.3213$ [s]

közvetlenül a Plant Simulation szimulációs modellbe került átvitelre. A gyártási folyamat sztochasztikus jellegét figyelembe véve az értékelést a modell több független futtatásával végeztük el.

A kapott eredményeket összehasonlítottuk a helyettesítő modell előrejelzéseiével. Ez az összehasonlítás lehetővé teszi nemcsak a Random Forest-modellek minőségének értékelését, hanem a helyettesítő megközelítés gyakorlati alkalmasságának felmérését is az ipari rendszer optimális paramétereinek meghatározása szempontjából.

4.2 A becült és a tényleges eredmények összehasonlítása

A helyettesítő modell segítségével kapott döntés megbízhatóságának értékelése érdekében a megtalált optimális paramétereket az eredeti szimulációs modell segítségével is ellenőriztük. Mivel a gyártási rendszer sztochasztikus, az értékelést több független szimulációs futtatás alapján végeztük el. A 4. táblázatban összehasonlítjuk a Random Forest modell által előre jelzett értékeket a szimulációs modellezés átlagos eredményeivel.

4. táblázat A validáció eredménye

Mutató	Előrejelzett érték	Szimulációk átlag-eredményei	Eltérés
Kapacitás	211.47 [db]	224.6 [db]	6.21 [%]
Átlagos torlódási idő	104.67 [s]	100.9 [s]	3.6 [%]
Meghibásodási idő	810.58 [s]	1152.18 [s]	42.14 [%]

Az eredmények azt mutatják, hogy a helyettesítő modell elég pontosan visszaadja a termelési rendszer főbb jellemzőit. A legkisebb eltérés az átlagos torlódási idő esetében figyelhető meg, amely 3,6 %-ot tesz ki, míg a termelékenység eltérése 6,21 %. Ez arra utal, hogy a Random Forest modell elfogadható pontossággal képes becsülni a rendszer termelékenységét és a termékek felhalmozódásának szintjét a megtalált optimális tartományban. A legnagyobb eltérés a berendezés meghibásodási ideje esetében figyelhető meg, ami 42,14 %-os érték. Ez az eltérés összefüggésben van a mutató nagyobb sztochasztikus változékonyságával és azzal, hogy az kevésbé reprezentatív a tanulási mintában. A teljesítménnyel és az átlagos torlódási idővel ellentétben a meghibásodási időt jelentősen nagyobb szórás jellemzi, ezért előrejelzése a helyettesítő modell számára bonyolultabb feladat.

4.3 Az eredmények megvitatása

A kapott eredmények azt mutatják, hogy a helyettesítő optimalizálás lehetővé teszi a számításigényes modellezési szakasz elválasztását a közvetlen optimalizációs kereséstől. A Random Forest modellek betanítása után az optimális paraméterkészlet keresése kizárólag a helyettesítő modellek gyors előrejelzései alapján történik.

Ennek során a validációs eredmények alapvető jelentőségűek. Még akkor is, ha a helyettesítő modellek tesztelése során magas R^2 determinációs együttható-értékeket kapunk, az optimalizálás minőségét nem csupán az egyes előrejelzések pontossága határozza meg, hanem az is, hogy a modell képes-e helyesen leképezni az optimális megoldások tartományát.

Így a javasolt megközelítést nem csupán a szimulációs modellezés eredményeinek közelítő becslésére szolgáló módszerként kell tekinteni, hanem a termelési rendszer paramétereinek felkutatására szolgáló eszközként is, amelynek során a talált megoldást kötelezően ellenőrizni kell a kiindulási szimulációs modellen.

5. ÖSSZEFOGLALÁS

A cikk a sztochasztikus gyártási rendszer optimalizálására alkalmazott szimulációs modellezést tárgyalja. A szimulációs modellezés eredményei alapján Random Forest modelleket hoztunk létre, amelyek lehetővé teszik a termelékenység, a késztermék-készletek szintje és a berendezések meghibásodásáig eltelt idő előrejelzését. Az optimális paraméterek meghatározásához normalizált célfüggvénnyel rendelkező genetikust algoritmust alkalmaztunk. A kapott megoldást a kiindulási szimulációs modell többszöri futtatásával további ellenőrzésnek vetettük alá. A becsült termelékenység 211,47 darab volt, míg a szimulációk eredményei alapján számított átlagérték 224,6 darabot ért el, ami 6,21 %-os eltérést jelent. Az átlagos felhalmozódási időre 104,67, illetve 100,9 másodperces értékeket kaptunk, 3,6 %-os eltéréssel. A legnagyobb

eltérés a meghibásodási idő esetében volt megfigyelhető: az előrejelzés szerint 810,58 másodperc, a szimuláció eredményei szerint pedig 1152,18 másodperc, ami 42,14 %-os eltérésnek felel meg. A kapott eredmények rámutatnak arra, hogy a helyettesítő modell alkalmazása ígéretes megoldás a gyártási rendszerek optimalizálásának felgyorsítására, ugyanakkor megerősítik azt is, hogy az optimális megoldást az eredeti sztochasztikus szimulációs modellen is ellenőrizni kell. A jövőbeli kutatások során a kidolgozott helyettesítő megközelítés továbbfejlesztését tervezzük alternatív gépi tanulási módszerek alkalmazásával, valamint azok pontosságának összehasonlításával a szimulációs modellezés eredményeinek közelítése során.

6. SUMMARY

This article discusses simulation modeling applied to the optimization of a stochastic production system. Based on the results of the simulation modeling, we developed Random Forest models that enable the forecasting of productivity, finished goods inventory levels, and the failure time. To determine the optimal parameters, we used a genetic algorithm with a normalized objective function. The resulting solution was further verified by running the initial simulation model multiple times. The estimated productivity was 211.47 units, while the average value calculated based on the simulation results was 224.6 units, representing a 6.21% difference. We obtained average congestion time of 104.67 and 100.9 seconds, respectively, with a difference of 3.6%. The largest discrepancy was observed in the failure time: 810.58 seconds according to the forecast, and 1,152.18 seconds according to the simulation results, which corresponds to a 42.14% discrepancy. The results obtained indicate that the use of the surrogate model is a promising approach for accelerating the optimization of manufacturing systems, while also confirming that the optimal solution must be verified using the original stochastic simulation model. In future research, we plan to further develop the proposed surrogate approach by applying alternative machine learning methods and comparing their accuracy in approximating the results of simulation modeling.

7. IRODALOM

- [1] MADU C. N.: Simulation in manufacturing: A regression metamodel approach, *Computers & Industrial Engineering*, Vol. 18, No. 3, 1990, pp. 381–389. [https://doi.org/10.1016/0360-8352\(90\)90060-Y](https://doi.org/10.1016/0360-8352(90)90060-Y)
- [2] BARTON R. R., MECKESHEIMER M.: Metamodel-Based Simulation Optimization, in *Handbooks in Operations Research and Management Science*, Vol. 13, 2006, pp. 535–574. [https://doi.org/10.1016/S0927-0507\(06\)13018-2](https://doi.org/10.1016/S0927-0507(06)13018-2)

- [3] HONG L. J., ZHANG X.: Surrogate-Based Simulation Optimization, in *Emerging Optimization Methods and Modeling Techniques with Applications*, INFORMS, 2021, pp. 287–311.
<https://doi.org/10.1287/educ.2021.0225>
- [4] SOARES DO AMARAL J. V., MONTEVECHI J. A. B., MIRANDA R. C., JUNIOR W.: Metamodel-based simulation optimization: A systematic literature review, *Simulation Modelling Practice and Theory*, Vol. 114, 2022, 102403.
<https://doi.org/10.1016/j.simpat.2021.102403>
- [5] LI M., YANG F., UZSOY R., XU J.: A metamodel-based Monte Carlo simulation approach for responsive production planning of manufacturing systems, *Journal of Manufacturing Systems*, Vol. 38, 2016, pp. 114–133.
<https://doi.org/10.1016/j.jmsy.2015.11.004>
- [6] ČERVENÁNSKÁ Z., KOTIANOVÁ J., VAŽAN P., JUHÁSOVÁ B., JUHÁS M.: Multi-Objective Optimization of Production Objectives Based on Surrogate Model, *Applied Sciences*, Vol. 10, No. 21, 2020, 7870.
<https://doi.org/10.3390/app10217870>
- [7] ANTONIADIS A., LAMBERT-LACROIX S., POGGI J.-M.: Random Forests for Global Sensitivity Analysis: A Selective Review, *Reliability Engineering & System Safety*, Vol. 206, 2021, 107312.
<https://doi.org/10.1016/j.ress.2020.107312>
- [8] CHEN M.-C., YANG T.: Design of manufacturing systems by a hybrid approach with neural network metamodeling and stochastic local search, *International Journal of Production Research*, Vol. 40, No. 1, 2002, pp. 71–92.
<https://doi.org/10.1080/00207540110073055>