

Storcz Tamás László

Adatvezérelt gépi tanulás az épületenergetikai
optimalizálásban

doktori értekezés

Témavezető:

Dr. Várady Géza György

Pécsi Tudományegyetem

Műszaki és Informatikai Kar

Multidiszciplináris Műszaki Tudományi Doktori Iskola

Nyilatkozat önálló munkáról, hivatkozások átvételéről

Alulírott, Storcz Tamás László, kijelentem, hogy ezt a doktori értekezést magam készítettem és abban csak a megadott forrásokat használtam fel. Minden olyan részt, amelyet szó szerint, vagy azonos tartalomban, de átfogalmazva más forrásból átvettem, egyértelműen, a forrás megadásával megjelöltem.

Pécs, 2023. augusztus 28.

Storcz Tamás László

Tartalomjegyzék

Bevezetés.....	5
Célkitűzés.....	7
Előzmények.....	9
A javasolt módszertan.....	15
Épületkonfiguráció ábrázoló módszerek.....	17
Moduláris térszervezés alapú konfiguráció tervezés.....	17
Konfiguráció előállítás.....	18
Moduláris térszervezésű konfiguráció validációja.....	20
Építészeti egybevágósági szűrés.....	24
Konfiguráció hatása a szimulációs eredményekre.....	31
Paraméter nélküli szimulációk elemzése.....	31
Paraméterezett szimulációk elemzése.....	33
Épületkonfiguráció leírók.....	41
Komplex indirekt leíró.....	42
Egyszerű indirekt leírók halmaza.....	43
Modul koordináták, mint direkt leírók.....	44
Keresési tér funkcionális pontfelhője.....	45
Surrogate modellek - szimulációk regressziós közelítése.....	46
Lineáris regresszió.....	47
Polinomiális regresszió.....	49
Regularizáció.....	50
Modellek értékelése.....	50
A becslések megbízhatósága.....	51
Lineáris regressziós eredmények.....	54
Regressziós döntési fa.....	57
Regressziós neurális hálózat.....	60

A hálózat tanítása	61
Bemenet vagy belső struktúra bővítés.....	63
Bias – variancia egyensúly	64
Rendszerparaméterek meghatározása	67
Eredmények.....	69
Pontosság.....	69
Hálózati struktúra választása.....	72
Konfiguráció leíró választás	78
Stabilitás	79
A véletlen mintaválasztás hatása.....	80
A modell véletlen inicializációjának hatása	81
Érzékenységvizsgálat	83
Döntési fa számára lényeges tulajdonságok.....	84
A polinomiális regresszió normalizált abszolút súlyai.....	85
Tézisek	88
Továbbfejlesztés lehetőségei.....	91
Irodalomjegyzék.....	92
Köszönetnyilvánítás	104
Összefoglalás.....	105
Summary	106

Bevezetés

Európa elsődleges energia felhasználásának több mint 40%-a épületeink létrehozására és üzemeltetésére vezethető vissza [1], [2]. Mivel ez igaz az energia előállítása során keletkező CO₂ kibocsátásra is, az ilyen célú energiafelhasználás csökkentése egyaránt gazdasági és környezetvédelmi elvárás is. Az építőipari és épületgépészeti technológia fejlődése, energiahatékonyságának növekedése folyamatosan csökkenti ezt az energia igényt, azonban az épülettervezés területeit (forma/konfiguráció, burkolat, térszervezés stb.) átfogó passzív tervezési koncepció alkalmazásával további jelentős, közel 80%-os energia megtakarítás érhető el [3]. Ha ennek visszamenőleges alkalmazása lehetséges volna, a világ energiaigénye akár 1/3-ával csökkenthető lenne. Az ilyen beruházások azonnali végrehajtása sajnos nem lehetséges. Ju et al. [4] munkája alapján az épületek élettartamának a fizikai élettartam mellett szociális, funkcionális és gazdasági komponensei is vannak. Így, bár az alkalmazható anyagok és technológiák több száz éves élettartamot is lehetővé tennének, a szociális környezet, a népesség mérete és struktúrája, valamint az épületekkel szemben támasztott funkcionális elvárások dinamikus változása miatt az épületek általában az elérhető leghosszabb fizikai élettartamnál lényegesen rövidebb idő után átépítésre vagy elbontásra és újjáépítésre kerülnek. A passzív tervezési elvek tehát rövid távon az új, közép és hosszú távon pedig az átépített, illetve újjáépített épületek esetében is alkalmazhatóak lennének. A jelenlegi épülettervezési eljárások azonban jellegükből adódóan valódi optimalizálás helyett mindössze néhány potenciális lehetőség közül választást tartalmaznak. Ugyanakkor ez a választható lehetőségek meghatározásának szokásokra támaszkodó módja nem garantálja az optimálisához közeli megoldás alkalmazását.

Szükséges tehát egy olyan eljárás kidolgozása, amely egyesíti a tervezésben résztvevők tudását és tapasztalatait annak érdekében, hogy adott komfortszint mellett csökkenjen az építőipari és épületfenntartási, üzemeltetési szektor energia felhasználása. Az Energia Design (ED) [5] a 2010-es évek elején kifejlesztett, a gyakorlatban is használt iteratív módszer, amely a tervezés során egyszerre veszi figyelembe az energiaigényeket és a humán komfort értékeket. A módszer épületenergetikai szimulációk heurisztikus rendszerét használja a tervezés területeinek különböző szintjein. Habár az ED alkalmazása szignifikánsan javíthatja az előállított egyedi épületek energia és komfort teljesítményét, nem foglalkozik az optimalitás kérdéskörével.

Amennyiben ez lehetséges, olyan eljárást kell kidolgozni, amelyben az optimális megoldás biztosítása érdekében az összes lehetőség vizsgálatára sor kerüljön, vagy a heurisztikával ellentétben a bejárando keresési tér vágása bizonyítottan hatékony legyen.

A keresési tér bejárásának meghatározásához meg kell határozni annak dimenzióit, vagyis az optimalizálás paramétereit, leíró változóit és azok értékkészletét.

Áttekintő cikkünkben [6] több mint 100 épület energetikai, komfort és környezet tervezés optimalizációs (Building Energy, Comfort and Environmental Design Optimisation - BECEDO) feladat megoldásával foglalkozó publikáció elemzése után arra a következtetésre jutottam, hogy a vizsgálatok döntő többsége az optimális megoldást az

- alkalmazott hűtő, fűtő, légcserélő rendszerek (Heating, Ventilation, Air Conditioning - HVAC) hatékonyságának növelése
- az épület falszerkezetének
- a felhasználás jellegének változtatásával igyekeznek elérni [7], [8].

Mivel a tervezés során alkalmazott, az épületkonfigurációt is tartalmazó kombinált optimalizációval 60%-os energiaigény megtakarítás és közel 80%-os környezeti hatás csökkenés érhető el [9], az épületkonfigurációnak az energia és komfort hatékonyságra gyakorolt hatását egyre többen vizsgálják. A bizonyított pozitív hatás [10] miatt a BECEDO kutatásokban is megjelenik kettő, az épületkonfigurációt is felhasználó eljárás. Az egyik a kiválasztott épületforma módosítása, a másik pedig az ED-hez hasonlóan néhány lehetséges épületforma független generálása. Mivel az épületforma az optimalizációs kutatások során is csak érintőlegesen, néhány eset vizsgálatán keresztül jelenik meg, a széles körben alkalmazott tervezési folyamatokban az épületforma továbbra is inkább művészi eszköz, nem pedig az optimalizáció alapjául szolgáló tervezési paraméter.

A vizsgált BECEDO megoldások további hátránya, hogy az ED-hez hasonlóan heurisztikus keresést, jellemzően genetikai algoritmust használnak, amely nem biztosítja az optimális eredményt.

Az összes lehetséges megoldás elkészítése és szimulációs eredményének összehasonlítása azért is nehézkes, mert az energetikai és komfort szimulációk előkészítése, elvégzése és az eredmények utófeldolgozása még automatizálható esetben is igen sok időt vesz igénybe. Ezen túl a törvényi szabályozások és a gazdasági szereplők közvetlen igényei sem követelik még ezt meg.

Célkitűzés

Kutatásom célja a ED módszer bővítéseként bemutatott Energia Design Szintézis (Energy Design Synthesis - EDS) eljárás támogatása. Az EDS kialakításának célja a valóban legjobb energia- és komfortteljesítménnyel rendelkező, optimális épületforma (konfiguráció) előállítása, kiválasztása. Ezért a javasolt eljárás az összes megépítésre és felhasználásra alkalmas épületkonfigurációt előállítja, majd azokat különböző építészeti jellemzőkkel látja el. Ilyenek például a falszerkezet, az ablakozás és az épület orientációja. Ezt követően a komplex energetikai és komfort szimulációkhoz az épületet mesterséges világítással és hűtő, fűtő és szellőztető berendezésekkel szereli fel, majd elhelyezi benne az egyéb eszközöket és a felhasználókat/lakókat. A szimulációs eredmények elemzésével egy teljesítmény alapján rendezett épületlista állhat elő, amely kijelöli az energetikai és/vagy komfort szempontok alapján optimális megoldást, valamint más nézőpontok bevonása esetén segíti a megvalósítandó, energetikailag optimálisához legközelebbi terv kiválasztását.

Jelen dolgozat célja az EDS első két lépésének, a megvalósítható épületek kiválasztásának és a komplex szimulációk elvégzésének támogatása gépi tanuló algoritmusok alkalmazásával. Ennek keretében egy jól alkalmazható épületkonfiguráció leíró eljárás meghatározása után az építészeti feltételeknek is megfelelő épületkonfigurációk kiválasztásának formális leírása, majd a kiválasztott épületkonfigurációkhoz tartozó komplex szimulációk lassú elvégzése helyett azok gyors becslésére regressziós eljárás választása, modell (surrogate model) készítése és értékelése történt meg.

A probléma megoldása alkalmazott informatikai központú, a dolgozatnak nem célja az alkalmazott építészeti szabályok, eljárások és paraméterek érvényességének vizsgálata, ellenőrzése, módosítása.

Kutatásaim során az alábbi kérdésekre kerestem a válaszokat:

1. Befolyásolja-e az épület geometriája az energiahatékonyságot?
2. Algoritmikusan előállítható az összes lehetséges épületforma?
3. Milyen építészeti szabályok szükségesek az elfogadható épületformák kiválasztásához?
4. A kiválasztott épületkonfigurációk száma csökkenthető építészeti egybevágósági szűréssel?
5. Helyettesíthetők az energetikai szimulációk kevésbé erőforrás intenzív regressziós eljárással?

6. Ha igen, milyen típusú regressziós modell és milyen paraméterezéssel alkalmas az energiaigény és komfort becslési feladatok ellátására és az EDS folyamatba integrálásra?
7. Milyen mértékben befolyásolja az épületforma az energetikai és komfort teljesítményt?

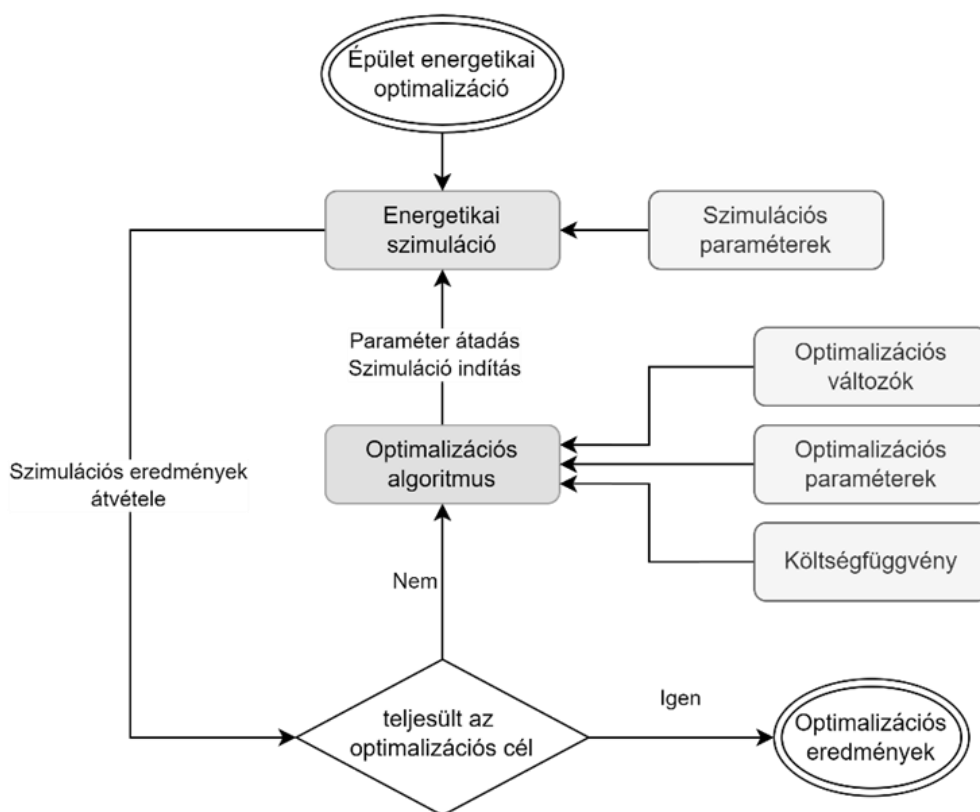
Előzmények

Az energiahatékonyság iránti igény látens módon ugyan, az épületek fenntartási költségein keresztül, de mindig is jelen volt a fenntartók mindennapi életében. A XIX. század második felében a kapcsolódó fő tudományok fejlődése lényegében alakította át a tervezési metodikát. A korábban alkalmazott tapasztalati alapú technológiákat tudományos alapú megoldások váltották fel. Az új tudományos irányzatot a XX. század technológiai fejlődése és globalizációja segítette elterjeszteni, a köztudatba építeni szabványokon, szabályozásokon és a média erején keresztül. A modern épületenergetika az 1980-es években, a passzív házak és az azokhoz kapcsolódó új technológiák, elvárások megjelenésével és az ezeket felhasználó új tervezési koncepció iránti igény kialakulásával kezdődött. [11]. A számítástechnika ugrásszerű fejlődése lehetőséget teremtett energetikai szimulációk a korábbiaknál lényegesen gyorsabb elvégzésére. A fentiek következményeként 1986-ban jelent meg az első épületenergetikai optimalizációval foglalkozó tanulmány [12], amely direkt keresést és energetikai szimulációt használt HVAC rendszer optimalizációjára. Az ilyen témájú tudományos tanulmányok száma a 2000-es évek közepéig lineárisan, ezt követően exponenciálisan emelkedett [13].

Az épület energiahatékonyság két fő komponenst foglal magába: az energia megtakarításért felelős passzív komponenseket, mint a falazat hőkapacitása és szigetelése, a napsugárzás elsődlegesen felhasznált fűtési és világítási energiája, az árnyékolás és a természetes szellőztetés; valamint a másodlagosan felhasznált energia előállításért, átalakításért, továbbításért és felhasználásért felelős aktív, épületgépészeti komponenseket.

A Sidney-i családi ház szimuláció alapú optimalizálását bemutató tanulmány [14] valódi optimalizáció helyett a változók kis száma és azok kevés választott diszkrét értéke által lehetővé tett *grid-search* algoritmust használt, ami a keresési tér minden pontjának szimulációs bejárását és azok közül a legjobb kiválasztását jelenti. Az optimalizáció alapja az építési, HVAC kialakítási és elektromos energia költségek voltak, a változók pedig a falak szigetelése, hőkapacitása, falak és ablakok szigetelése és az éjszakai légcseré arány voltak. Az eredmény pedig, hogy a megfelelő paraméterek beállítása mellett teljes költségre optimalizált családi ház nem igényelt aktív HVAC eszközöket. Azonban, mivel a vizsgálat egy konfigurációra és lokális klímaadatokra vonatkozott, nem általánosítható.

A szimuláció alapú valódi optimalizációs eljárások, melyek általános struktúráját az 1. ábra szemlélteti, egy energetikai és komfort szimulációs eszközt, valamint egy optimalizációs eljárást tartalmaznak.



1. ábra: Szimulációt alkalmazó épület energetikai optimalizációs rendszer struktúrája

A szimulációs eszköz számára minden esetben szükség van az épületkonfiguráció valamilyen reprezentációjára. Ez általában az épület részletes tervrajza, amely igényli az épületkonfiguráció részletes tervezését, valamint nehezíti a szimulálni kívánt konfiguráció változtatását, hiszen az új épület tervének ismételt elkészítése szükséges. Több mint száz BECEDO eljárást áttekintve megállapítottam [6], hogy azok egy részében a szimulációs bemenetek igen, de az optimalizálandó változók nem tartalmazzák az épületkonfigurációt, csak annak valamilyen indirekt leírását, pl. méreteit, arányait [15]. Megállapítottam továbbá, hogy az épületkonfiguráció az energiaigény meghatározás lényeges komponense, azt a tervezés során figyelembe kellene venni. Az ezt megvalósító, épületkonfigurációval is foglalkozó BECEDO eljárások egyik típusa egy előre kiválasztott épületformát módosít [16], [17], [18], míg másik típus néhány lehetséges, függetlenül generált épületformát használ [19], [20], [21]. Mindkét megoldás eredménye nagyban függ a kiinduló épületeket kiválasztó eljárás hatékonyságától. Mivel a szimulációk előmunkálatai, számításai és az eredmények utófeldolgozásai is időigényesek, az ilyen eljárások csak korlátozott számú szimuláció elvégzését teszik lehetővé. Ezek alapján belátható, hogy nem garantálják az optimális, vagy ahhoz közeli megoldás előállítását.

Lényeges továbbá, hogy a fenti kutatások során alkalmazott épületkonfigurációt reprezentáló közvetett leíró változók (fő méretek, tető mérete, különböző geometriai és funkcionális elemek mérete és aránya) csak előre meghatározott épületforma esetében szolgáltatnak elegendő információt az épület tényleges kialakításához, megépítéséhez, így nem eredményezik az optimális épületkonfiguráció előállítását. Az optimális megoldás biztosításának lehetőségét tovább gyengíti, hogy a vizsgált kutatásokban [22], [23], [24], [25], [26] leggyakrabban genetikai algoritmust [27] használnak. Az evolúciós elveken alapuló valószínűségi kereső eljárások hatékonysága jelentősen függ a keresési tér genetikai reprezentációjának minőségétől, valamint az evolúciós és genetikai operátorok algoritmusainak és azok paramétereinek megválasztásától. Ugyan az optimalizáció során alkalmazott valószínűségi változók segítik elkerülni a lokális optimumba ragadást, de nehezítik a keresési tér szisztematikus bejárását. Ezért az ilyen jellegű megoldások alkalmazásának célja egy elegendően jó megoldás megtalálása, de nem garantálják a globális optimum megtalálását.

A kialakított és bemutatott moduláris térszervezésű épület reprezentációban a visszalépéses (backtracking) algoritmus [28], [29] és az építészeti szabályokon alapuló konfiguráció validációs eljárás [30] az EDS fő irányvonalához igazodva lehetővé teszi az összes, meghatározott építészeti szabályoknak megfelelő, megépíthető és élhető családi ház jellegű lakóépület gyors és egyszerű előállítását. Az így kiválasztott konfiguráció tervezetekből a moduláris struktúrát felhasználva, alapértelmezett modul paraméterekkel, a részletes tervek elkészítése nélkül, akár automatizáltan is előállíthatók a szimulációs eszközök által igényelt épületkonfiguráció leírások. Ezek segítségével a komplex energetikai szimulációk már elvégezhetőek, könnyebben automatizálhatók.

Azonban a nem épületformához kapcsolódó építészeti (pl. ablakozás, falszerkezet, orientáció) és épületgépészeti (pl. hűtés, fűtés, szellőzés, világítás) paraméterek által kifizített sokdimenziós hipertér vizsgálandó pontjainak száma még a dimenziók diszkrétizálása esetén is nagyon nagy. Annyira, hogy az optimális megoldás megtalálásához szükséges összes lehetőség komplex szimulációjának elvégzése bizonyosan kívül esik bármely építési projekt megvalósítási idején. Ez alapján a legjobb megoldás megtalálása nem biztosított. Az EDS eljárás által megcélzott optimum kiválasztáshoz szükséges komplex szimulációs eredmények előállításához tehát a szimulációs számítások elvégzésének idejét is jelentősen rövidíteni kell. A komplex szimulációs számítások lényegesen gyorsabban elvégezhető regressziós eljárással történő helyettesítése lehetővé teheti a szükséges mennyiségű energiaigény és komfortszint meghatározás elvégzését, ezáltal a valóban optimális megoldás meghatározását.

Az analitikus szimulációknál lényegesen kisebb számítási igénnyel rövidebb idő alatt eredményt adó adatvezérelt gépi tanuló algoritmusok [31] energiaigény becslést célzó alkalmazásával foglalkozó publikációk száma az utóbbi 10 évben ötszörösére emelkedett [32]. A vizsgált kísérletekben folytonos, vagy diszkrét függvények becslésére különböző regressziós módszereket használtak. Az épületenergetikai optimalizációs rendszerekben a szimulációk helyettesítésére alkalmazott közelítő modellek a „surrogate model” nevet kapták [33], [34], [35].

Épület energiaigény becslésre leggyakrabban alkalmazott modellek egyike a lineáris regresszió [36] [37], [38], [39], [40] és annak polinomiális- és autoregressziós változatai [41] kiegészítve L1 (Least Absolute Shrinkage and Selection Operator – LASSO) [42], [43], L2 (Ridge) [44], [45] vagy kombinált (Elastic Net) regularizációval, melyek célja a modell komplexitásának minimalizálása.

Más vizsgálatok döntési fa alapú regressziós eljárást (Classification And Regression Tree – CART) [46], [47] használnak, amely osztályozásra és regresszióra is hasonlóképpen alkalmazható. Az osztályozás jellegű alkalmazás során [48] lakóépület energiaigény szintjét becsülték 92%-os pontossággal. Az összehasonlításban, mely Spanyolország elektromos áram fogyasztásának 10 perces felbontású becslésére regressziós döntési fát, gradiens gyorsított regressziós döntési fát (Gradient Boosting Regression Tree – GBRT) és regressziós fák véletlen gyűjteményét (Random Forest – RF) alkalmaztak [49], a GBRT 2%-os átlagos relatív hibával becsülte az idősort.

A lineáris regressziós és döntési fa alapú modellek adatvezérelt, de paraméter nélküli statisztikai eljárással készülnek. A modellek szakértők számára is jól érthetőek, azonban nem képesek a feladat megoldása szempontjából lényeges komplex jellemzők létrehozására és azok kiválasztását is csak korlátozott hatékonysággal végzik. A felhasznált komplex jellemzők létrehozását és a modell egyszerűsítése érdekében történő kiválasztását informatikus és építész szakértők együttműködésével, szakmai tudásuk, tapasztalatuk felhasználásával kell elvégezni. Napjainkban a számítási kapacitás növekedésével a gépi tanulás olyan adatvezérelt eljárásai kerülnek előtérbe, melyek nem igénylik a feladat kiírást tartalmazó tématerület szakértőinek bevonását a megoldás kialakításának mélységeibe, ők csak a feladat meghatározásában és az eredmények értékelésében vesznek részt. A lényeges jellemzőket, összefüggéseket önálló feldolgozó elemek hálózatba kapcsolt rendszere a tanulás során képes egyre mélyebb szinten meghatározni és felhasználni.

Az univerzális közelítési tételre alapuló sekély neurális hálózat alapú modellek [50], [51] egy rejtett réteget tartalmaznak, ezért a komplex feature extrakciós képességüket a rejtett réteg méretének növelésével pótolják. A mély neurális hálózat alapú módszerek [52] több tíz, akár több száz rejtett réteget használnak, melyek a megelőző rétegek által kialakított jellemzőkből új, komplexebb tulajdonságokat hoznak létre. Ezáltal a rejtett rétegek mérete kisebb, korlátos maradhat. A mély neurális hálózatok hátránya azonban, hogy a hiba visszaterjesztéses tanító algoritmus működése során a kimeneti hiba hatása a hálózat eleje felé haladva csökken, vagy akár teljesen meg is szűnik. Az eltűnő gradiensnek nevezett jelenség kiküszöbölésére alkalmazott *dropout* megoldás a tanítás során folyamatosan, sztochasztikusan változtatja a hálózat struktúráját, ezért annak általános approximációs képességét vizsgálni kell [53]. A hálózatok mélységén kívül lényeges a feldolgozó elemek kapcsolatainak mennyisége és jellege is. A regressziós feladatok megoldására leggyakrabban használt neurális hálózati struktúrák a rétegenként teljesen előrecsatolt (Dense Neural Net – DNN, FeedForward Neural Net - FFNN) [54], vagy általános regressziós neurális háló (General Regression Neural Net - GRNN) [55]. A lokális információ feldolgozására, általában képek elemzésére [56] a rétegenként lokálisan előrecsatolt konvolúciós (Convolutional Neural Net – CNN) [57], [58], [59] hálózatot, míg idősorok elemzésére, közelítésére általában memóriaként működő visszacsatolást is tartalmazó (Recurrent Neural Net – RNN, Long Short Term Memory – LSTM, Gate Recurrent Unit – GRU) [60], [61], [62], [63] neurális hálózatot használnak. Az alábbi megoldások valamilyen neurális hálózat alapú modellt alkalmaznak.

Kuvaiti irodaépületek hűtési terhelésének becslésére létrehozott általános regressziós neurális hálózat (GRNN) becslési teljesítményét és HVAC rendszer optimalizációs eljárásban történő felhasználhatóságának lehetőségét vizsgálták [64]. A rendszer tanításához három irodaépület négy éves (1997-2000), órára lebontott hűtési terhelésének szimulált adatait használták. A teljesítményt a 2001-es szimulált adatokon végezték. A vizsgálatok kimutatták, hogy a GRNN jól használható az adott regressziós feladat ellátására, optimalizációs feladatok támogatására.

A lakóház aktuális energiaigényének regressziós becslésére visszacsatolt neurális hálózatot, Support Vector Machine-t (SVM) [65], [66] és gradiens gyorsított regressziós fát használó és összehasonlító [67] tanulmány szerint a GBRT teljesített a legjobban. A teljesítmény mellett a modellválasztás fontos összetevője volt megszerzett ismeretek szakértői tématerületre történő visszavezethetősége is. A publikus épületek energiaigényének mesterséges neurális hálóval, osztályozó és regressziós döntési fával, valamint regressziós fák véletlen gyűjteményével

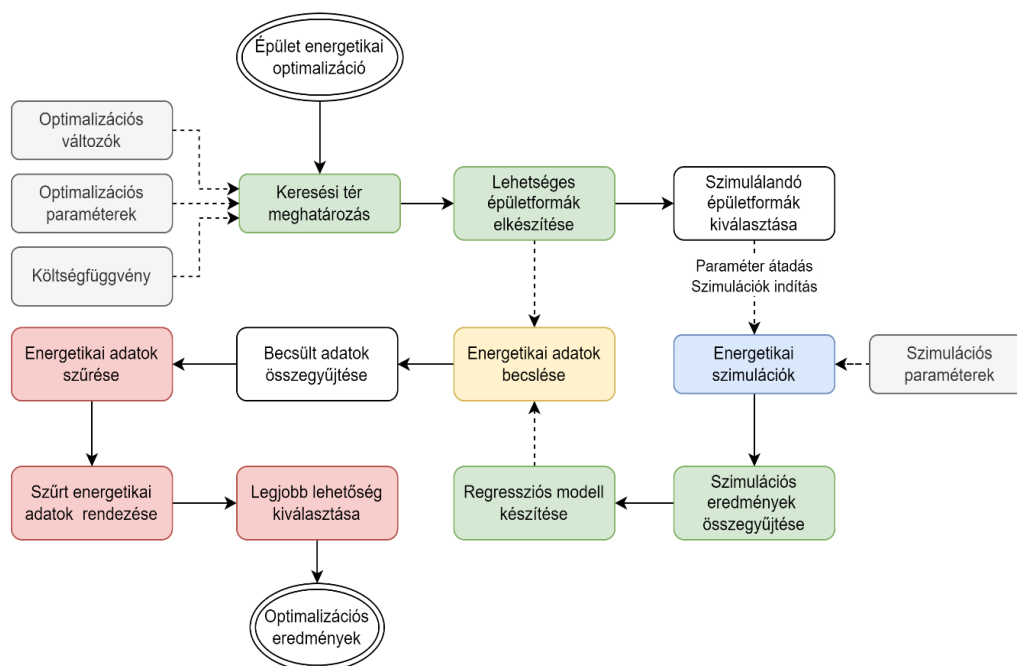
történő becslését összehasonlító tanulmány [68] a Boruta tulajdonság kiválasztási eljárással [69] módosított CART-ot részesíti előnyben.

Gépi tanuló eljárások felhasználásának egy összehasonlító elemzése [70] polinomiális regressziót, mesterséges neurális hálózatot (ANN) és support vector regressor-t (SVR) hasonlít össze, melyek közül a polinomiális regressziót javasolja. Egy döntési fát, random forest-et (RF), SVR-t és ANN-t összehasonlító elemzés [71] választása a könnyen értelmezhető döntési fára esik. Az elmúlt közel 30 év több mint száz, mesterséges neurális hálózatok épület energetikai elemzési célú alkalmazásával foglalkozó tanulmányokat áttekintő munka [72] szerint a tanulmányok jelentős része HVAC energiaigénnyel, vízfűtéssel és -hűtéssel, belső levegő-hőmérséklet becsléssel, valamint ezekből adódó teljes energiaigénnyel foglalkozott, regressziós modellnek pedig leggyakrabban teljesen előrecsatolt (DNN) vagy visszacsatolt (RNN) neurális hálózatot használt, a becslési feladat jellegének megfelelően. Egy neurális hálókat összehasonlító tanulmányban [73] konvolúciós és visszacsatolt komponenseket tartalmazó neurális hálózatot használtak családi házak elektromos energiaigényének becslésére. A feladat itt a felhasznált energia adatok idősorként értelmezése és az értékek jövőbeni becslése volt, amiben sokkal inkább a felhasználási szokásokat vették figyelembe, mint az épület építészeti és gépészeti paramétereit. Az ilyen típusú feladatok megoldásában a visszacsatolt hálózatok általában jobban teljesítenek, ezt a kutatás eredményei is igazolták, hiszen a bemutatott komplex neurális hálózat jobb eredményt adott a homogén jellegűeknél.

A feldolgozott tanulmányokban alkalmazott adat vezérelt gépi tanuló eljárások EDS-ben történő felhasználásának akadálya, hogy általában létező épületek mérési adatait használják a modellek elkészítéséhez és értékeléséhez. Kis számban ugyan, de előfordul olyan tanulmány is, ahol a modellek készítéséhez használt adatokat szimulációval állítják elő [12], [14], [64], azonban ezekre az esetekre is igaz, hogy mindössze egy, vagy csak néhány épületkonfigurációt használnak és a HVAC rendszer optimalizálását célozzák. Az így kapott modellek a tanítás alapjául szolgáló épületek energiaigényének becslésre alkalmasak, de nem tartalmazzák az épületkonfiguráció módosíthatóságának lehetőségét, ezért nem illeszthetők épületkonfigurációs paramétert is tartalmazó BECEDO vizsgálatokhoz, így az EDS-hez sem.

A javasolt módszertan

Az általam javasolt módszertan az EDS 2. ábrán bemutatott olyan megvalósítása, amelyben az ED bővítéseként az optimum meghatározása az összes lehetőség közül a legjobb kiválasztását jelenti. Ehhez az összes építészeti elfogadható konfiguráció meghatározása után azok komplex energetikai és komfort teljesítményének szimulációit olyan helyettesítő (surrogate) regressziós modellekkel végzem, melyek dinamikusan képesek kezelni az épületformát, így az közvetlenül tervezési változóként jelenhet meg.



2. ábra: Javaslat a kibővített energetikai szimulációt, regressziót és optimum választást alkalmazó rendszer funkcionális felépítésére

A javasolt eljárásban az optimalizáció során figyelembe vett teljesítményeket (fűtési energia, hűtési energia, világítási energia, hőmérséklet komfort, világítás komfort) nem szükséges a bemutatott diszkrét, moduláris szervezésű keresési térben előállított, építészeti elfogadható összes épületformára előállítani. Az I. tézisem felhasználásával az azonos energetikai és komfortteljesítménnyel rendelkező konfigurációk halmazainak meghatározása után ezeket a halmazokat elegendő egy tetszőleges elemükkel reprezentálni. Így az optimum meghatározása egy szűkebb épületforma halmaz teljesítmény becslésével, majd a legjobbnak ítélt kiválasztásával történik.

Az épületforma tervezési változóként történő figyelembevételének fontosságát a II. tézisemben fogalmazom meg.

Az épületkonfiguráció tervezési változóként történő felhasználást biztosító reprezentációt és az azt felhasználó surrogate modelleket a III. tézisem keretében mutatom be. Jelen munkámban az

épületkonfiguráció optimalizáció még nem teljes, a leghatékonyabb konfiguráció kiválasztása csak az egyes kimeneti adattípusok alapján külön végezhető. Ennek oka, hogy az építész szakértők jelenleg is dolgoznak az energetikai és komfort teljesítmények mérésének egy metrikába integrálásán, ennek elméleti értelmezésén és gyakorlati megvalósításán.

Az általam javasolt regressziós modellek külön tanítandó, így eltérő paraméterezéssel rendelkező példányai alkalmasak energetikai (hűtés, fűtés, világítás) és komfort (hőérzet, világítás) szimulációs számítások megfelelő pontosságú helyettesítésére. A szimuláció helyettesítő rendszer komponensek képesek bemenetként felhasználni a bemutatásra kerülő diszkrét, funkcionális 3D térben ábrázolt, moduláris térszervezéssel készített épületkonfigurációt. Így használható azonos feltételekkel függetlenül, vagy prototípus módosítással előállított különböző épületkonfigurációk tulajdonságainak becslésére, de a regressziós művelet elvégzésének nagy sebessége miatt alkalmas lehet az összes potenciális konfiguráció vizsgálatára, így az EDS-ben történő alkalmazásra is. A modellek elkészítéséhez szükséges tanító adatokat pedig az épületkonfigurációt is magába foglaló keresési tér csökkentett számú pontján végzett, automatizált energetikai szimulációval állítom elő. Ezt a lehetőséget az biztosítja, hogy a bemutatott moduláris konfiguráció reprezentációból (előre meghatározott feltételek mellett) a szimulációkhoz szükséges épülettervek előállíthatók.


A moduláris térszervezésű keresési térben az épületformák modulokból történő összeállítása algoritmizálható, amely algoritmus több, rendelkezésre álló számítógép/processzor esetén jól párhuzamosítható, így a párhuzamos feldolgozás feladat kiosztásának és az eredmények összegzésének menedzselését leszámítva a szimulációs folyamat végrehajtási ideje a feldolgozó egységek számával arányosan csökkenthető.

Épületkonfiguráció ábrázoló módszerek

Az első kutatási kérdésre választ keresve épületenergetikával foglalkozó tudományos kutatások eredményeinek vizsgálata és összehasonlítása [6] alapján kijelentettem, hogy az épületkonfigurációnak szignifikáns hatása lehet az éves energiaigényre, így az energiahatékony tervezést az épület konfiguráció optimalizálására is érdemes kiterjeszteni. Azonban a fentiek alapján azt is felismertem, hogy az ilyen optimalizációs rendszerek kialakításának egyik fő akadálya az épületkonfiguráció túl komplex reprezentációja. Vagyis az épület energetikai szimulációinak elvégzésére alkalmas terv nagy és változó mennyiségű folytonos értékű paramétert tartalmaz, ami miatt a keresési tér túl nagy és részletes. A probléma megoldására véges, minimális méretű keresési tér meghatározására egy diszkrét értékű paraméterrendszer kialakítása szükséges, amely pusztán a diszkrét értékek alkalmazásából fakadóan is jelentősen csökkenti a keresési tér bejárható pontjainak számát, azonban valódi jelentősége a paraméterek számának korlátozásában rejlik.

Moduláris térszervezés alapú konfiguráció tervezés

Az épület tervezési és építési paramétereinek korlátozását a funkcionális megkötések nélkül legkönnyebben úgy tehetjük meg, ha az épületet előre meghatározott méretű modulokból állítjuk össze. A bemutatott moduláris térszervezési rendszer alap gondolata egy 181.5 m² alapterületű, 6 téregységből kialakított családi ház jellegű épületből fakad, melyet alkotó építőelemek a 3. ábrán látható, egységesen 5.5m x 5.5m x 3.0m méretű (hosszúság, szélesség, magasság), funkció alapján nem megkülönböztetett téglatestek. Az építőelemek mérete illeszkedik egy családi ház átlagos szobaméretéhez, de abban a megvalósítás során területfelosztással kisebb funkcionális blokkok is kialakíthatók.



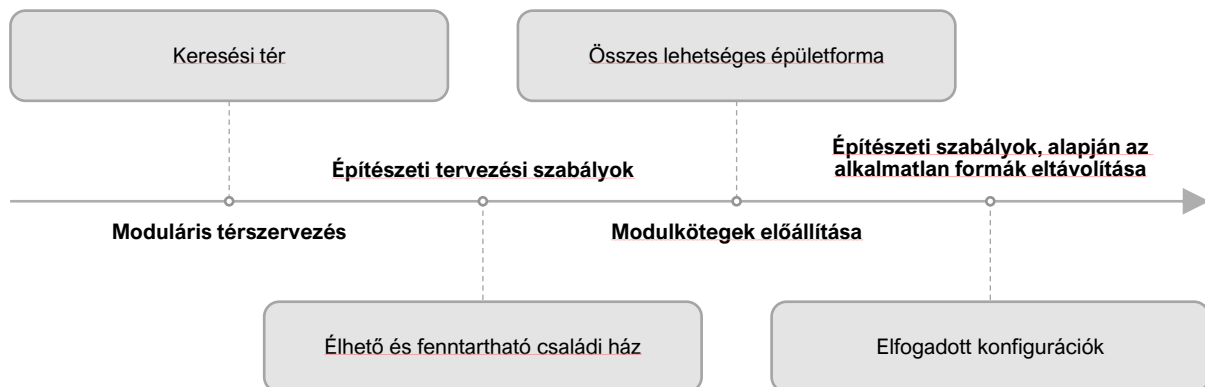
3. ábra: Térszervezési alapmodul formája és méretei

Az épületkonfigurációk kialakítása a blokkok felhasználásával úgy történik, hogy azokat egy blokk méretű egységekből álló háromdimenziós diszkrét koordináta-rendszerbe helyezzük. A diszkrét egységű koordináta-rendszer azt jelenti, hogy az egyes tengelyek mentén az építőelemek csak a megfelelő méretük egész számú szorzatánál kezdődhetnek. Az így

tervezhető épületek száma végtelen, ezért a tervezési teret építészeti megfontolások alapján szűkíteni kell. Mivel a cél összefüggő épület tervezése, a 6 építőelemet felhasználó keresési tér egy 6x6x6-os diszkrét háromdimenziós térre korlátozható, melyben az így kialakuló 216 téregység mindegyikébe legfeljebb egy épület alkotóelem helyezhető. Az építőelemekkel méretezett, diszkrét elhelyezés eredményeként az elemek átlapolása nem lehetséges, a szomszédos elemek pedig oldalukkal, élükkel vagy csúcsukkal találkoznak. Amennyiben a legkisebb (x, y, z) koordinátákkal rendelkező cellához a $(0, 0, 0)$ modul koordinátát rendeljük, a pozitív tengelyek diszkrét egységei mentén tőle legtávolabbi cella az $(5, 5, 5)$ modul koordinátát kapja. A keresési térben összeállított épület tehát egyértelműen leírható a keresési térben elhelyezett építőelemek háromdimenziós modul koordinátaival. Belátható, hogy a reprezentáció független a keresési tér és az építőelemek előre meghatározott méretétől és számától.

Konfiguráció előállítás

Az EDS eljárás jelentőségét a legjobb választás meghatározása adja, ezért lényeges a 2. ábra folyamatának első két tevékenységként felvázolt lépésekben az összes lehetséges épületkonfiguráció előállítása, melyhez a 4. ábrán bemutatott és az alábbiakban részletezett eljárást használok [30].



4. ábra: Moduláris térszervezés alapú épületkonfiguráció előállítás

Az épületek meghatározott keresési térben történő moduláris előállításához a backtracking algoritmust használtam, melynek C [74] és Python [75], [76] implementációit a 5.a. és 5.b. ábra mutatja be. A python implementációban a nyelv átveszi a fejlesztőtől a numerikus típus ábrázolási korlátjából fakadó forráskód optimalizációs feladatot, a rekurzív implementáció alkalmazása során a felhasznált építőelemek száma is dinamikusan változtatható.

```

void generate() {
    long size = width * depth * height;
    for (long i1=0; i1 < size-5; i1++)
        for (long i2 = i1+1; i2 < size-4; i2++)
            for (long i3=i2+1; i3 < size-3; i3++)
                for (long i4=i3+1; i4 < size-2; i4++)
                    for (long i5=i4+1; i5 < size-1; i5++)
                        for (long i6=i5+1; i6 < size; i6++)
                            // architectural compliance check
                            check_rules(i1, i2, i3, i4, i5, i6);
}

```

(a) Egymásba ágyazott ciklusok C nyelven

```

def generate(start, size, blocks, coordinates):
    for i in range(start, size - blocks + 1):
        new_coordinates = coordinates + [i]
        if blocks > 1:
            generate(
                i + 1, size, blocks - 1,
                new_coordinates
            )
        else:
            # validate/process configuration
            check_rules(new_coordinates)

# entry point of generation
generate(0, length * width * height, number_of_blocks, [])

```

(b) Rekurzív implementáció python nyelven

5. ábra: konfiguráció generáló backtracking algoritmus implementációk

Ehhez szükséges a háromdimenziós modulkoordináták (x, y, z) és a többlépcsős backtracking által használt szekvenciális koordináták (SN) közötti át- (1) és visszaalakítás (2-4) leírása.

$$SN = x + y \cdot \text{hosszúság} + z \cdot \text{hosszúság} \cdot \text{szélesség} \quad (1)$$

$$z = SN // (\text{hosszúság} \cdot \text{szélesség}) \quad (2)$$

$$y = (SN \% (\text{hosszúság} \cdot \text{szélesség})) // \text{hosszúság} \quad (3)$$

$$x = (SN \% (\text{hosszúság} \cdot \text{szélesség})) \% \text{hosszúság} \quad (4)$$

Ahol a // operátor az osztás egész részét a % operátor pedig az osztás maradékát határozza meg.

A kutatásban használt családi ház összeállításához a rendelkezésre álló 6 építőelem 6 x 6 x 6 méretű keresési térben történő elhelyezésével $\binom{216}{6} = 131.513.824.548$ féle különböző épület konfiguráció hozható létre.


Moduláris térszervezésű konfiguráció validációja

Ahhoz azonban, hogy a generált elméleti épület megépíthető és élhető családi ház legyen, meg kell felelnie bizonyos építészeti kritériumoknak:


1. az épület a földön áll (sem a földben, sem felette nem kezdődhet)
2. az épület legfeljebb három szint magas lehet
3. az 1 emeletnél magasabb épület legfeljebb három egység hosszú és széles
4. a szomszédos építőelemek oldalaikkal kapcsolódnak és az épület kompakt
5. egy tengely mentén legfeljebb négy elem csatlakozhat, ezzel elkerüljük a „folyosó” jellegű épületeket
6. az épület legfeljebb egy alátámasztás nélküli elemet tartalmazhat
7. nem lehet két vagy több olyan elem egymáson, aminek nincs oldalsó szomszédja, ezzel kizárjuk a „tornyok” kialakítását

Az 1, 2, 4, 5 szabályok alkalmazásával a tervezési tér 5x5x3 méretűre csökkenthető. Az optimális megoldás keresési terének ilyen csökkentésével a lehetséges épületkonfigurációk száma $\binom{75}{6} = 201.359.550$ változatra, majdnem három nagyságrenddel csökken. Ez jelentős hatású változtatás, hiszen az építészeti követelmények és azok teljesítettségét ellenőrző konfiguráció validációs eljárás a konfigurációs opciók ismételt előállítását és vizsgálatát igényli. Az on-demand generálás a tesztelés, hibajavítás során indokolt, de bizonyítottan hibátlan működés esetén az egyszeri előállítás, majd tárolás a megfelelő infrastruktúra kiépítése esetén hatékonyabb lehet. A kísérletben használnál nagyobb tervezési tér vagy komplexebb építészeti szabályrendszer esetén a kérdéskör felülvizsgálata szükséges.


A tervezett épület szűkített tervezési térbe helyezése nem jelenti a megkötések teljesítését, azokat egyenként és pontosan vizsgálni kell. Ehhez az épület moduláris szerkezetét leíró gráf 6. ábrán látható háromdimenziós szomszédsági gráfját és funkcionális blokkmátrixát használtuk, amelyeket a csúcsok modulkoordinátáiból állítottunk elő. Két csomópont között akkor áll fenn szomszédsági viszony, akkor létezik gráf él, ha koordinátáik tengelyenként számított abszolút különbségének összege pontosan 1.



(a) Blokk vázlat



(b) Szomszédsági gráf



(c) Funkcionális mátrix

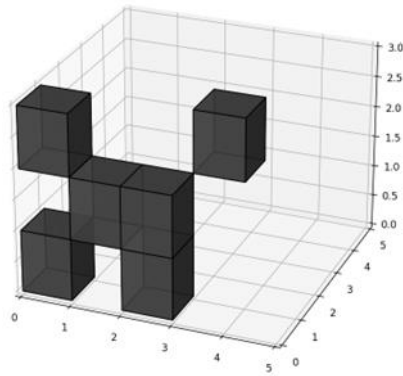
6. ábra: Épületkonfiguráció reprezentációk

A 6.b és 6.c ábrán bemutatott szomszédsági gráf és funkcionális blokkmátrix ábrákon az építőelemet reprezentáló csomópont az épületelem térfogategységnek közepén helyezkedik el. A dinamikus szoftveres vizualizáció során a megértés segítése érdekében az ábrák forgathatók, nagyíthatók. A 6.c ábra funkcionális blokkmátrixában két típusú funkcionális elem szerepel. A piros az épülethez tartozó, a szürke az épületen kívüli funkcionális elem jelölő színe.


A vizsgálati lépések pszeudokód jellegű megvalósítása:

Az implementációkban az indexek 0 alapúak, így az X, Y, Z tengelyek mentén 0-4, 0-4, 0-2 értékeket vehetnek fel.

1. a legkisebb Z koordináta 0: $\min(Z) == 0$
2. a legnagyobb Z koordináta legfeljebb 3 lehet: $\max(Z) < 3$
3. az épület legfeljebb 2 emelet magas, vagy legfeljebb 3 egység hosszú és széles:
 $\max(Z) < 2$ vagy $(\max(X) - \min(X) + 1) \leq 3$ és $\max(Y) - \min(Y) + 1 \leq 3$
4. diszkrét derékszögű koordináta-rendszerben 4-szomszédsági kapcsolattal vizsgálva a gráf összefüggő (nem összefüggő konfiguráció a 7. ábrán látható):
 - a. tetszőleges pontból indított szélességi/mélységi keresés során az érintett pontok megjelölése
 - b. a bejárás után az érintetlen pontok létének vizsgálata



(a) Blokk vázlat




(b) Szomszédsági gráfja

7. ábra: Nem összefüggő épület


5. a funkcionális blokkmátrix $Z=0$ szintjén az X és Y tengelyek mentén nem tartalmazhat 4-nél több összefüggő elemet:

A funkcionális blokkmátrix 0. szintjét soronként és oszloponként vizsgálni kell. Ha a vizsgált elem épület, akkor, ha az előző is az, az összefüggő elemek száma 1-gyel nő. Ellenkező esetben az összefüggő elemek száma legyen 1. Ha az összefüggő elemek száma meghaladja a 4-et, a konfiguráció sérti a szabályt, a vizsgálat megszakítható.

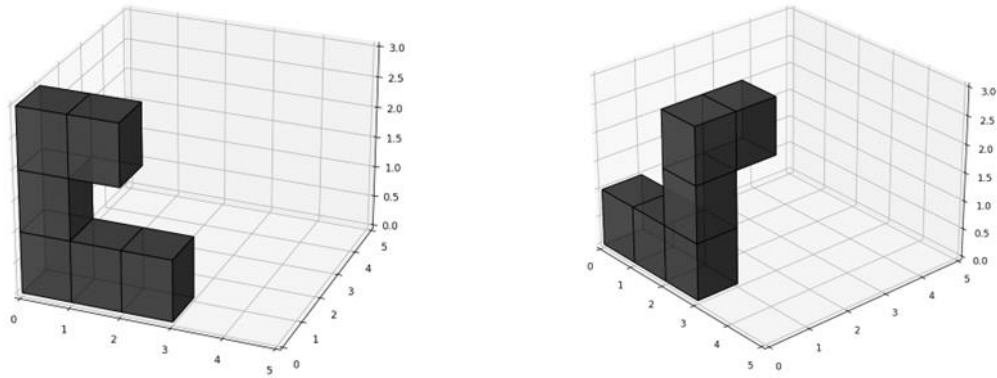
6. legfeljebb 1 lehet azon elemek száma, melyek nincsenek a földön alátámasztva. Ez nem közvetlenül azt jelenti, hogy az adott elem alatt kell épületelemnek lenni. Hibás lehetőségeket 8.a-b ábra, míg szabályos konfigurációt az 8.c ábra szemléltet.



(a) Hibás elemek egymás mellett



(b) Hibás elemek egymáson




(c) Szabályos konfigurációk

8. ábra: #6 szabályt törő (a)-(b) és szabályos (c) konfigurációk

7. az 1. szint felett nem lehet két olyan elem egymáson, aminek nincs oldalsó szomszédja

A funkcionális blokkmátrixot oszloponként vizsgálva a 0. szint felett, amennyiben az aktuális épületelemnek nincs oldalsó szomszédja, a torony elemek számát növelni kell. Ha a torony elemek száma eléri a 2-t, a konfiguráció sérti a szabályt, a vizsgálat megszakítható. Az 8. ábra konfigurációi nem sértik ezt a szabályt, míg a 9. ábra konfigurációja igen.



9. ábra: #7 szabályt törő torony jellegű konfigurációk

A visszalépéses generálással tehát $\binom{75}{6} = 201.359.550$ különböző konfigurációt állítottunk elő, melyből az építészeti szabályok alkalmazásával 201.356.978 konfigurációt kizártunk az 1. táblázat szerinti eloszlással.

1. Táblázat: az építészeti szabályok alkalmazása által kizárt konfigurációk száma szabályonként


#1	#2	#3	#4	#5	#6	#7	Elfogadott
15.890.700	0	169.176.721	16.282.086	97	7164	210	2572

A szabályok alkalmazása a sorszámuk szerint történik, amint egy konfiguráció szabálytalannak minősül, a vizsgálata befejeződik és az adott szabály oszlopában jelenik meg. A #2 ellen azért nem vét egyetlen konfiguráció sem, mert a keresési teret három emelet magas konfigurációkra korlátoztuk. Mivel egy-egy konfiguráció több szabályt is szeghet, a szabályok eltérő sorrendben történő alkalmazása az egyes szabályok által kizárt konfigurációk számát módosíthatja. Az építészeti szabályokat teljesítő konfigurációk száma 2572, azonban az energetikai vizsgálatokba vonandó konfigurációk halmaza tovább csökkenthető. Mivel egy épületforma több építészeti szabályt is törhet, a szabályok alkalmazási sorrendjének változása hatással lehet az adott szabály által kizárt konfigurációk számára.


Építészeti egybevágósági szűrés

Belátható, hogy az összes lehetséges épületkonfiguráció visszalépéses előállítására és építészeti validációjára után több olyan épületkonfiguráció-csoport is a vizsgálandók között maradt, melyek tagjainak energetikai és komfort teljesítménye egyezik, ezért építészeti (energetikai és komfort) szempontból azonosnak tekinthetők. Az ilyen konfiguráció halmazok kevesebb elemmel történő reprezentációjával tehát a vizsgálandó elemek száma tovább csökkenthető. Belátható, hogy egy épület X és/vagy Y tengely mentén történő eltolása esetén nem változik annak energetikai és komfort teljesítménye.

Mivel az épület tájolását minden esetben a főhomlokzat tájolásával határozzák meg és a főhomlokzat kiválasztása a felület alapján egyértelmű, a generált épületformák Z tengely körüli forgatásának az épület energetikai tulajdonságára nincs hatása. Így ezen művelet alkalmazása azonos energetikai és komfort teljesítményű épületeket eredményez. A 10. ábrán látható, hogy a konfigurációk X és/vagy Y tengely mentén történő forgatása geometriailag hasonló blokkstruktúrát, de eltérő épületméreteket eredményez. Ezáltal megváltozhat a főhomlokzat és az energetikai és komfort teljesítmény,



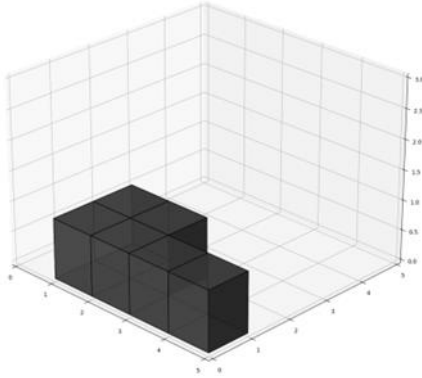
(a) Egyszintes épület




(b) Forgatással keletkező kétszintes épület

10. ábra: Az X tengely körüli elforgatás eredménye

Két épülettől akkor is azonos energetikai és komfort teljesítmény várható, ha a két épület az XZ vagy YZ síkkal párhuzamos sík mentén szimmetrikus. Belátható, hogy a 11. ábrán bemutatott tükrözés nem módosítja az épület főhomlokzatát, a naphoz viszonyított szimmetrikus elhelyezések pedig összességében azonos energetikai és komfort teljesítményt eredményeznek.




(a) Eredeti épület




(b) Tükrözéssel keletkező épület

11. ábra: Azonosan kezelt, tengelyesen szimmetrikus konfigurációk

Az XY síkkal párhuzamos szimmetria azonban felcserélné az épület szintjeit. A 12.a ábra elfogadott alakzatából, az XY tengellyel párhuzamos, magasságban felező sík mentén történő tükrözéssel olyan alakzat áll elő, amely sérti a #6 építészeti szabályt, ezért az ilyen jellegű transzformáció alkalmazása nem megengedett.



(a) Eredeti épület



(b) Tükrözéssel keletkező épület

12. ábra: Az XY sík menti tengelyes tükrözés eredménye

Más magasságba helyezett tükrözési tengelysík eredménye olyan épület lenne, amely nem a földre (földbe, vagy a föld fölé) épül, így a kiindulástól eltérő energetikai és komfort értékekkel rendelkezik, vagy sérti az építészeti szabályokat, ezért nem megépíthető.

Fontos megjegyezni, hogy az építészeti egybevágóság elégséges, de nem szükséges feltétele az azonos energetikai és komfort teljesítménynek, vagyis az építészeti nem egybevágó épületek

is rendelkezhetnek azonos energetikai és/vagy komfort teljesítménnyel, ezért az ilyen jellegű vizsgálat csökkenti, de nem garantáltan minimalizálja a vizsgálandó konfigurációk számát.

A fentiek okán az építészeti egybevágósági vizsgálatok során a transzformációk közül az X és Y tengelyek körüli forgatásokat, valamint az XY síkra történő tükrözést kizárjuk.

A bemutatott moduláris térszervezésű konfiguráció reprezentációs rendszerben az épület konfigurációk építészeti egybevágóságának vizsgálatához és azonos energetikai és komfort teljesítményű halmazba soroláshoz **az alábbi tételt fogalmaztam meg, melyre az I. Tézisem épül:**

Tétel: Jelölje az építészeti elfogadható geometriai transzformációk közül R a Z tengely körüli forgatást, M_X az XZ és M_Y az YZ tengelyek mentén történő tükrözést, X és Y pedig az adott tengelyek mentén történő eltolást. Ekkor a keresési tér összes **építészeti egybevágó** moduláris épület konfigurációja előállítható egy kiindulási konfigurációból egy R forgatást, vagy egy M_X vagy M_Y tükrözést, vagy egy R forgatást és egy M_X vagy M_Y tükrözést, valamint az ezeket opcionálisan követő X és/vagy Y eltolásokat tartalmazó transzformáció sorozattal.

Bizonyítás:

A reprezentációs rendszerben, a bizonyítás során használható transzformációk:

Forgatások: A forgatási műveletek bevezetésére azért van szükség, mert az épületek építészeti orientációjának meghatározása az épület főhomlokzatára vonatkozik. Mivel a csak Z tengely körüli geometriai orientációban (és X, Y pozícióban) eltérő épületek ugyanazzal a főhomlokzattal rendelkeznek, ezért ezek azonosan kezelendők. A korábban említettek szerint a forgatások minden esetben a Z tengely mentén történnek, így ezek a műveletek nem változtatják meg a konfiguráció alapterületét, magasságát. Azonban a modulok négyzetes alapterülete lehetővé teszi a konfiguráció forgatását úgy, hogy az a moduláris koordináta-rendszer egységeivel továbbra is kompatibilis legyen. A moduláris koordináta-rendszerrel való kompatibilitás megtartása érdekében a forgatási szögeknek 90° többszöröseinek kell lenni.

$$R_{360} = R_0: (x, y, z) \rightarrow (x, y, z) = I \quad (5)$$

$$R_{90} = R_1: (x, y, z) \rightarrow (width - y, x, z) \quad (6)$$

$$R_{180} = R_2: (x, y, z) \rightarrow (width - x, depth - y, z) \quad (7)$$

$$R_{270} = R_3: (x, y, z) \rightarrow (y, \text{depth} - x, z) \quad (8)$$

Tükrözések: a tengelyes tükrözések tengelysíkjai a jelölt tengely mellett minden esetben párhuzamosak a Z tengellyel is. A XY síkra történő tükrözést a korábban említett építészeti, statikai megfontolásból nem alkalmazzuk.

$$M_X: (x, y, z) \rightarrow (x, \text{depth} - y, z) \quad (9)$$

$$M_Y: (x, y, z) \rightarrow (\text{width} - x, y, z) \quad (10)$$

Eltolások: Z tengely menti eltolást nem használunk, ugyanis az eltolás után érvényes épületek generált formái az 1. építészeti szabályt megszegik.

$$S_X: (x, y, z, s) \rightarrow (x + s, y, z) \quad (11)$$

$$S_Y: (x, y, z, s) \rightarrow (x, y + s, z) \quad (12)$$

A használt lineáris transzformációk tulajdonságai:

$$X \circ I = I \circ X = X \text{ ahol } X \in \{R, M, S\} \quad (13)$$

$$(E \circ F) \circ G = E \circ (F \circ G) \text{ ahol } E, F, G \in \{R, M, S, I\} \quad (14)$$

$$R_i = R_{i+k*4} \text{ ahol } k \in \mathbb{N}^+ \quad (15)$$

Az (5)-(10) egyenlegben leírt transzformációk és tulajdonságaik felhasználásával az alábbi azonosságok határozhatók meg:

$$R_i \circ R_j = R_k \text{ ahol } k = (i + j) \% 4 \quad (16)$$

$$M_X \circ M_X = I \quad (17)$$

$$M_Y \circ M_Y = I \quad (18)$$

$$M_X \circ M_Y = M_Y \circ M_X = R_2 \quad (19)$$

$$M_Y \circ I = M_Y \circ M_X \circ M_X = R_2 \circ M_X \quad (20)$$

$$M_X \circ R_i \circ M_X = R_{(4-i) \% 4} \quad (21)$$

$$M_X \circ R_1 \circ M_X = R_3 \quad (21a)$$

$$M_X \circ R_2 \circ M_X = R_2 \quad (21b)$$

$$M_X \circ R_3 \circ M_X = R_1 \quad (21c)$$

$$M_X \circ R_i = R_{(4-i) \% 4} \circ M_X \quad (22)$$

$$M_X \circ R_1 = R_3 \circ M_X \quad (22a)$$

$$M_X \circ R_2 = R_2 \circ M_X \quad (22b)$$

$$M_X \circ R_3 = R_1 \circ M_X \quad (22c)$$

Tegyük fel, hogy létezik egy, a fenti forgatás (5)-(8) és tükrözés (9)-(10) transzformációk tetszőleges véges sorozat! Az (16)-(19) azonosságok ismételt felhasználásával az egymást követő, azonos típusú tranzakciók egyszerűbb formába írásával és az azonosság művelet elhagyásával a kiindulási sorozat R és M transzformációk egymást váltó sorozatává alakítható. Ezt követően a (20) azonosság felhasználásával a sorozatból az M_Y transzformáció helyettesíthető $R_2 \circ M_X$ párral, így a sorozatból az M_Y művelet eltávolítható. Az (16) azonosság ismételt alkalmazásával a sorozat R és M_X transzformációk váltakozó sorozatává alakítható. A (21a)-(21c) azonosságok alkalmazásával az eredmény egy, két, vagy három lépéses transzformáció sorozat. Három lépéses esetben bizonyosan $R_i \circ M_X \circ R_j$ műveletek követik egymást. A kettő vagy három műveletből álló sorokon a (22.a)-(22.c), majd a (16) azonosságok alkalmazandók. Eredményül egy legfeljebb két lépés hosszú sorozatot kapunk, amelyekből a pontosan két lépés hosszú művelet sor $R \circ M$ formátumú. Ugyanis két alakzat akkor építészeti egybevágó, ha távolságtartó transzformációkkal (forgatás, tükrözés, eltolás) egymásra képezhetők. Mivel az eltolások a transzformációs szekvencia végére mozgathatók és ott egy X és egy Y irányú eltolásra összevonhatók, továbbá a forgatások és tükrözések tetszőleges sorozata a fent bemutatott módon legfeljebb két transzformációs lépésre rövidíthető, a tétel bizonyított.

Következmény 1: Mivel a transzformációs rendszerben az X és Y eltolások mellett 3 forgatás és 2 tükrözés művelet alkalmazható, a fenti tétel alapján X és Y eltolások nélkül $3 + 2 + 3 * 2$, vagyis a kiindulási konfiguráció mellé 11 energetikai és komfort teljesítményben azonos készíthető. Az eltolásokkal ezek

$$count_{shift} = (length - size_x) \cdot (width - size_y) \quad (23)$$

különböző pozícióba mozgathatók, ahol a *length* és *width* értékek a keresési tér, a *size* pedig a konfiguráció adott tengely mentén mért legnagyobb méreteit jelölik.

Következmény 2: Az 1. következmény megfordítása, hogy két tetszőleges konfiguráció építészeti egybevágóságának vizsgálatához elegendő az egyik konfiguráción a (24) képletben meghatározott, legfeljebb 12 (az azonossággal együtt, hiszen a generált konfigurációt is vizsgálni kell) transzformációt és azok origóba eltolását elvégezni. Amennyiben ezek közül


egyik sem viszi azt az origóba tolt másik konfigurációba, akkor a két konfiguráció építészetileg nem egybevágó.

$$|Identity| + |R| + |M| + |R| \cdot |M| = 1 + 3 + 2 + 3 \cdot 2 = 12 \quad (24)$$


A $|*|$ jelölés az adott típusú, különböző eredményt szolgáltató transzformációk számát jelenti.

Az építészetileg egybevágó konfigurációk kiszűrését a tételt és következményeit felhasználva végezzük. A generálás során listát készítünk az *elfogadott* konfigurációkról. A listába csak olyan konfiguráció kerülhet, amely sem a generált, sem a 11 transzformált, origóba pozícionált orientációjában nem szerepel még a listában. Ugyan a visszalépéses konfiguráció generáló eljárás kizárja két *azonos* konfiguráció előállítását, azonban olyan egybevágó konfigurációk létrehozását nem, melyek orientációja és/vagy pozíciója eltér. Így a pozíció összehasonlítás elvégzéséhez a generált orientációt is ellenőrizni kell. Az építészetileg megfelelő konfigurációk építészeti egybevágóság szerinti szűrése után a 13.a-c ábrán látható, összesen 167 különböző érvényes konfiguráció maradt.


A tapasztalatok alapján az épülő családi házak legnagyobb számban kétszintes épületek, ami illeszkedik a létrehozható épületformák meghatározott szintek szerinti eloszlásához. A további szimulációs és regressziós vizsgálatokat ezeken az elfogadott épületforma terveken végezzük.



(a) Egyszintes épület konfigurációk



(b) Kétszintes épület konfigurációk




(c) Háromszintes épület konfigurációk

13. ábra: elfogadott egyedi épület konfigurációk forrás: [77]

Konfiguráció hatása a szimulációs eredményekre

A hipotéziseim felállításához, a modellek megalkotásához 5010db, IDA ICE programban végzett energetikai és komfort szimulációval előállított mintát használtam. A szimulációk során építész szakértőnek az elfogadott 167 moduláris épületkonfiguráció diszkrét funkcionális reprezentációja alapján meg kellett tervezni a szimulálandó épületeket, azokat a 14. ábra szerint fel kellett szerelni építészeti (ablakozás, orientáció) és épületgépészeti (szigetelés, hűtő és fűtő, légcserélő rendszer) komponensekkel, felhasználási jellemzőkkel stb.

Majd a sokéves statisztikán alapuló időjárás adatok felhasználásával elvégezni az épület teljes éves (365 napos) energetikai (fűtés, hűtés, világítás) és komfort (termikus, megvilágítás) szimulációját. A napokra végzett szimulációk éves összesítésével álltak elő a 167 épületkonfiguráció egyes paraméterezett eseteihez tartozó éves szimulált energiaszükséglet és komfort adatok, melyeket a kutatásomban, mint szimulációs adatbázist használtam fel.




14. ábra: Épület konfiguráció különböző ablakozással forrás: [77]

Paraméter nélküli szimulációk elemzése

A szimulációk készítése során célkitűzéseim között elsőként megfogalmazott kutatási kérdésem megválaszolására hipotézist állítottam fel, mely szerint az épületformának jelentős hatása van

az éves energiaigényre. A felállított hipotézis igazolására vagy elvetésére először a magyarországi klímaviszonyok között legmeghatározóbb energiatípus, a fűtési energiaigény szimulációinak elemzését végeztem el úgy, hogy a vizsgálat leginkább az épületforma energetikai tulajdonságaira fókuszáljon. Ezért a szimulációs számításokban felhasznált épület nem tartalmazott sem ablakot a szoláris energia felhasználására, sem pedig aktív HVAC elemeket, továbbá az épület főhomlokzatának orientációja sem szerepelt a vizsgálati paraméterek között. Az egyes épületkonfigurációkhoz számított éves fűtési energiaigények szerint rendezett adatsorban a konkrét konfiguráció geometriai jellemzőit nem elemeztem, csak azt vizsgáltam, hogy a konfigurációk geometriai eltérései milyen mértékben módosíthatják a fűtési energiaigényt. A 15. ábra X tengelyén tehát nem konfiguráció azonosító, hanem energiaigény szerinti sorszám szerepel.



15. ábra: Épület konfigurációk fűtési energia igényei növekvő sorrendben

A 15. ábráról leolvasható, hogy az energiaigény szerint rendezett épületkonfiguráció lista első, legjobb konfigurációja 13.163kWh/év, míg az utolsó, legrosszabb 18.461kWh/év fűtési energiát igényel. A két szélső érték által közrefogott intervallum, 5297kWh/év fűtési energiaigény különbség kizárólag az épületforma által okozott eltérés. Ez az eltérés az optimális (legkisebb) érték arányában 40%. Ez azt jelenti, hogy azonos egyéb paraméterek mellett a legjobb helyett a legrosszabb konfiguráció választása esetén az éves energiaigény 40%-kal romolhat. Ez jelentősnek mondható, így a hipotézist nem vettem el, az első kutatási kérdésekre adott közelítő válasz: Az energiahatékonyság nagymértékben függ az épület formájától. [30]

Paraméterezett szimulációk elemzése

Az eddig elvégzett szimulációk azonban nem valószerűek, hiszen az emberek megfelelő komfortérzetének biztosításához természetes megvilágítás, a belső hőmérséklet hőérzeti komfort tartományon belül tartása és légfrissítés, légcserre szükséges. Ezért a szimulációt végző építész szakértők az épületeket a további szimulációk során ablakozással és aktív HVAC eszközökkel szerelték fel. Mivel az ablakozási arány eltérő a fő- és más homlokzatok között, a napsugárzás energiájának felhasználása szempontjából lényeges paraméter a főhomlokzat tájolása. Valamint az aktív HVAC eszközök energiafogyasztása összefügg a falazat szigetelési és hőkapacitási tulajdonságaival, ezek a változók is a vizsgálati paraméterek közé kerültek. [78]

A komplex energetikai és komfort szimulációk jellemzői:

- A szimulációk elvégzéséhez szükséges adatok:
 - Aktív, épületgépészeti paraméterek – alapértelmezett
 - hűtés, fűtés, szellőztetés
 - Passzív, építészeti paraméterek
 - épület főhomlokzat orientáció (5 érték) – Orientation, Ori
 - falazat szigetelést és hőkapacitást meghatározó szerkezet azonosítója (2 érték) – Wall structure, Structure, Struct

Az első falszerkezet (struct. 1) olyan, közel minimális szerkezetekkel rendelkezik, amelyek megfelelnek a magyar épületenergetikai törvény (7/2006 V.24. TNM) aktuális követelményeinek, vagyis 30 cm vastag külső téglafalból, 8,57 cm külső hőszigetelésből ($U_{\text{wall}} = 0,24 \text{ W/m}^2\text{K}$), 16 cm-es betonpadló 10 cm-es szigeteléssel és 15 cm kavics ($U_{\text{floor}} = 0,28 \text{ W/m}^2\text{K}$) és 20 cm-es betontető (födém), 20 cm-es szigeteléssel ($U_{\text{roof}} = 0,17 \text{ W/m}^2\text{K}$). A háromrétegű üvegezés U-értéke $1 \text{ W/m}^2\text{K}$

A második szerkezet (struct. 2) fejlett hőtulajdonságokkal rendelkező szerkezeteket tartalmaz, amelyek 60 cm vastag külső téglafalból, 30 cm külső hőszigetelésből állnak ($U_{\text{wall}} = 0,11 \text{ W/m}^2\text{K}$), 16 cm betonpadlóból 18 cm szigeteléssel és 15 cm kavicsból (Padló = $0,17 \text{ W/m}^2\text{K}$) és 20 cm beton tetőből(födém) 25 cm szigeteléssel ($U_{\text{roof}} = 0,14 \text{ W/m}^2\text{K}$). A háromrétegű üvegezés U-értéke $0,7 \text{ W/m}^2\text{K}$

- fal-ablak arány (3 érték) – Wall-Window rate, WWR

A főhomlokzatok 30%, 60% és 90% arány került alkalmazásra. A legmagasabb ablakarányú homlokzat nyílászáró szerkezetének méretét a legalacsonyabb $A_{\text{env}} / S_{\text{tot}}$ arányú geometria határozta meg, mivel ez rendelkezett a legkisebb főhomlokzati felülettel. A legalacsonyabb értéket pedig a megfelelő nyílászárókkal rendelkező lakóházban minimálisnak elfogadott ablak/fal aránya határozta meg. A középső értéket pedig a minimális és a maximális érték számtani közepe adta. Az alárendelt homlokzatok 7,5%, 15% és 30%-os ablak/fal arányt kaptak

- épületkonfiguráció, épületforma (167 konfiguráció)

- Energetikai és komfort szimulációs számítások IDA ICE program segítségével
 - Nehezen automatizálható, kézi elő- és utófeldolgozást igényel

- Szimulációs eredmények

- éves fűtési energiaigény – Heating energy, HE
- éves hűtési energiaigény – Cooling energy, CE
- éves világítási energiaigény – Lighting energy LE
- az éves különböző típusú energiaigények összegeként előálló éves teljes energiaigény – Total energy, TE, Sum energy, SE
- Hőmérséklet komfort – Thermal comfort, TC
- Természetes megvilágítási faktor – Daylight factor, DF

A 2. táblázatban olvashatók a szimulációs eredmények lényeges statisztikái. A minimum és maximum értékekből az összes energiaigény összetételét lehet meghatározni, a hisztogramokból pedig leolvashatók az egyes energia és komfort értékek gyakoriságai. Ezek,


valamint az ezekkel arányosított hibaértékek használhatók az elkészített modellek teljesítményének értékelése során.

2. táblázat: szimulált energia és komfortadatok statisztikai jellemzői:

Data	Adatsor jellemzők		Hisztogram
Éves fűtési energia igény	Minimum	5486	<p>[db]</p> <p>[kWh/év]</p>
	Maximum	15098	
	Intervallum	9612	
Éves hűtési energiaigény	Minimum	99	<p>[db]</p> <p>[kWh/év]</p>
	Maximum	3261	
	Intervallum	3162	
Éves világítási energiaigény	Minimum	915	<p>[db]</p> <p>[kWh/év]</p>
	Maximum	3008	
	Intervallum	2093	

Hőmérsékleti komfort	Minimum	6	
	Maximum	69.36	
	Intervallum	93.36	
Természetes megvilágítási faktor	Minimum	14	
	Maximum	70	
	Intervallum	55.87	


Az elvégzett $5 \times 2 \times 3 \times 167 = 5010$ paraméterezett szimulációk által szolgáltatott fűtési energiaigények hatékonyság szerint rendezett, a konkrét épületforma elemzése nélküli alakulását a 16. ábra szemlélteti.



16. ábra: Paraméterezett épület konfigurációk fűtési energia igényei hatékonyság szerint csökkenő sorrendben

Az optimális eset energiaigénye 5.486 kWh/év, a legrosszabb eseté 15.098 kWh/év a kialakuló különbség 9.612 kWh/év, ez az optimális érték arányában 175%-os romlást jelent. Vagyis az optimális helyett a legrosszabb paraméterek választása az éves fűtési energiaigényt majdnem kétszeresével növeli. Természetesen az energiaigények most bemutatott eltéréseit nem kizárólag az épületforma eltérései okozzák, hanem a szimulációs paraméterek ismeretlen hatásainak összeadódása.

Amennyiben a vizsgálataimat épületkonfigurációk geometriai változásai által okozott fűtési igény eltérésre szeretném fókuszálni, a paraméterezett szimulációk eredményeit csoportosítani kell az összes többi változó lehetséges értékének permutációi szerint. Így összesen $5 \times 2 \times 3 = 30$ adatszoport áll elő, melyek mindegyikében a 167 különböző konfiguráció azonos paraméterekkel számított energetikai és komfort adatai találhatóak meg. Ezen csoportok mindegyikében meghatároztam az energiaigény-intervallumokat és azokat az optimális energiaigényekkel arányosítottam. A csoportokat jellemzők általános leírói az arányok csoporton belüli átlagai lettek. Mivel egyes paraméter permutációs esetek eredményeiben a legjobb és legrosszabb épületkonfigurációk hűtési energiaigényei közötti eltérés az optimális érték akár 700-900%-át is elérhette, az eltérések megfelelő vizualizációja érdekében a függőleges tengelyen *logaritmikus skálát* alkalmaztam.

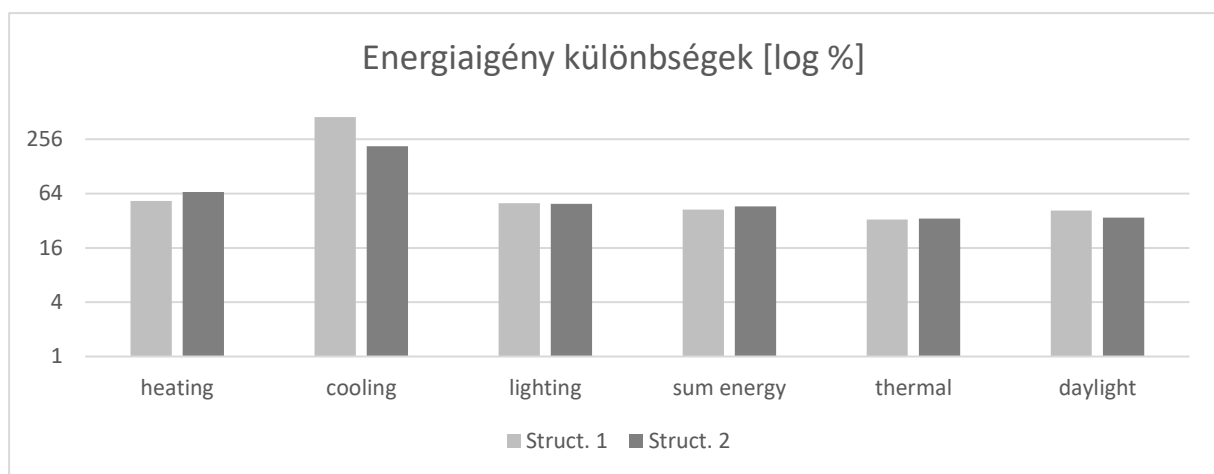


17. ábra: Épület geometriai változásai által okozott átlagos energiaigény eltérések

A bemutatott 17. ábráról leolvasható, hogy a fűtési energiaigény értékek az első szimulációkhoz viszonyítva csökkentek. A minimum 13.163 kWh/év-ről átlagosan 8.066 kWh/év-re, 39%-kal, a maximum 18.461 kWh/év-ről átlagosan 12.683 kWh/év-re, 32%-kal csökkent, a konfigurációk geometriája által okozott fűtési energiaigény szóródása abszolút értékben

681kWh/év mértékben csökkent, az optimális megoldás arányában kifejezett relatív energiaigény szóródás pedig 40%-ról 60%-ra, 20%-kal nőtt.


A paraméterezett szimulációk adatainak további elemzése során megvizsgáltam, hogy az épületkonfiguráción felüli szimulációs paraméterek hogyan módosítják az épületkonfiguráció választás energetikai hatásait. A vizsgálatot a falazattípus paraméternél kezdtem, ezért ennek két lehetséges értéke mentén két adatkört hoztam létre. Az adatkörökben ismételten elvégeztem a paraméter permutációk mentén történő csoportosítást, majd a kialakult 2x15, egyenként 167 elemet tartalmazó csoportban az intervallum meghatározását és az optimális értékkel történő arányosítását.



18. ábra: Épület geometriai változásai által okozott átlagos energiaigény eltérések falstruktúra csoportonként, az optimális lehetőség arányában

A 18. ábráról leolvasható, hogy a fűtési energia esetében a falazat hőkapacitásának növelése kis mértékben, de növeli az épületgeometria relatív hatását. Ez a következtetés további vizsgálatot igényel, ugyanis a falszerkezet hőszigetelő képességének javulásától épületfizikai számítások alapján az ellentétes eredmény volna várható. A következtetésem ellenőrzésére megvizsgáltam annak alapjául szolgáló értékek alakulását.


A 19. ábrán látható, hogy az energiaigény minimumok és maximumok az energetikai számításokkal összhangban egyaránt csökkentek. A konfiguráció relatív hatásának növekedését az okozza, hogy a minimum és maximum értékek körülbelül azonos 20% körüli mértékben csökkennek, így az általuk meghatározott intervallum szinte változatlan, mindössze 5%-kal csökkent. Az intervallumok minimum értékekkel történő arányosítása így 15%-kal nőtt.



19. ábra: Energiaigény minimumának, maximumának és különbségük abszolút változása a falszerkezet kialakításának függvényében

A fentiek alapján megállapítható, hogy az épületkonfiguráció fűtési energiaigényre gyakorolt hatására vonatkozó következtetésem a bemutatott adatokkal és a korábbi épületgépészeti számításokkal is összhangban van. A hűtési energia esetében jelentősen, az optimum arányában kifejezve kb. felére csökkenti azt. A világítási energiaigényre a falszerkezet belátható okok miatt nincs hatása. Az összes energiaigény esetében az egyes energiakomponensek hatásai a felhasználási súlyokat is figyelembe véve kiegyenlítik egymást, vagyis a falstruktúra megválasztása összességében csak nagyon kis mértékben befolyásolja a konfigurációnak az összes energiaigényre gyakorolt, az optimum arányában kifejezett 43-46%-os hatását. Az épületgeometria komfort értékekre gyakorolt hatását vizsgálva a 18. ábra utolsó két oszlopcsoportjáról leolvasható, hogy az optimális érték arányában a termikus komfort esetében a nagyobb hőkapacitású falszerkezet alkalmazása a konfiguráció hatását szinte egyáltalán nem befolyásolja, az 33%-ról 34%-ra változik. A falszerkezet megválasztása ugyanígy csak minimális hatással van a természetes megvilágításra is. Ez esetben az épületforma hatása 38%-ról 35%-ra csökken.


Amikor az épületkonfiguráció energiaigényekre és komfortszintekre gyakorolt hatását a falablak arányának vonatkozásában vizsgáltam, a 20. ábra alapján kijelenthettem, hogy a relatív ablakméret változása a hűtési energia és a hőmérséklet komfort esetében okoz jelentős változást az épületkonfiguráció hatásában.



20. ábra: Épület geometriai változásai által okozott átlagos energiaigény eltérések fal-ablak arány csoportonként, az optimális lehetőség arányában

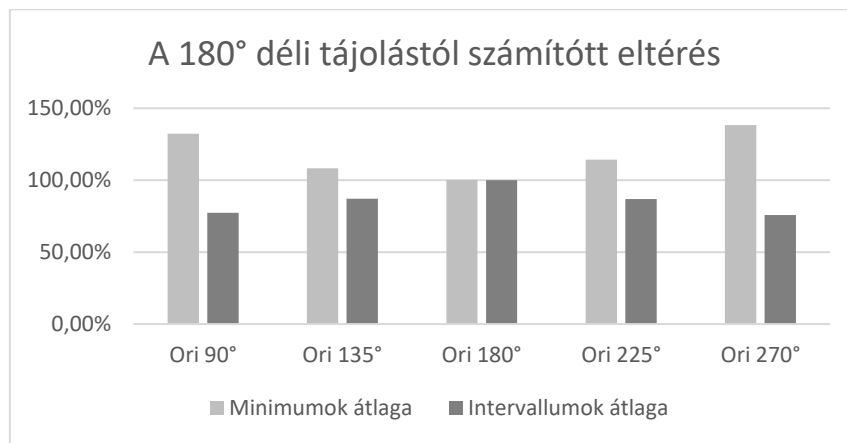
A hűtési energiaigény esetében a relatív ablakméret növelése csökkenti az épületforma hatását, míg a hőkomfort esetében növeli azt. Kis mértékben növeli a fűtési energiaigényre és ugyancsak kis mértékben csökkenti a megvilágítási energiaigényre gyakorolt hatást. A súlyozott összegek hatásaként az épületformának az összes szükséges energiaigényre gyakorolt hatása a relatív ablakméret növelésével csak kis mértékben csökken.

Az orientáció által okozott konfiguráció hatásváltozást bemutató 21. ábrán látható, hogy az épület főhomlokzatának déli tájolás esetén legnagyobb a konfigurációnak a fűtési energiaigényre gyakorolt relatív hatása, attól bármely irányba elforgatva ez a relatív hatás csökken.



21. ábra: Épület geometriai változásai által okozott átlagos energiaigény eltérések orientáció csoportonként, az optimális lehetőség arányában

A 22. ábra jól szemlélteti az okot. A főhomlokzat déli tájolásához képest az épületet bármely irányba forgatva a konfiguráció hatását leíró energiaigény szóródási intervallum csökken, míg a minimális (optimális) energiaigény nő. Így az intervallumhossz és az optimális érték relatív hatást kifejező hányadosa is csökken.



22. ábra: Épület geometriai változásai által okozott átlagos energiaigény eltérések orientáció csoportonként, az optimális lehetőség arányában

Fordított a hatás a világítási energiaszükséglet és hozzá kapcsolódó természetes megvilágítási komfort esetében. Vagyis az épület legnagyobb ablakfelületét a naptól elfordítva nő annak jelentősége, hogy mekkora az ablakokat tartalmazó oldalsó homlokzatok mérete, amit alapvetően az épületforma, vagyis az épületkonfiguráció határoz meg.

A fentiek alapján, az épületforma energiaigényre gyakorolt hatására felállított hipotézisemet igazoltnak tekintem, vagyis az épületkonfiguráció hatással van az energiaigényre és a komfort fokokra. Az egyes szimulációs paraméterek hatását az Érzékenységvizsgálat fejezetben vizsgálom pontosabban, részletesebben.

Épületkonfiguráció leírók

Az első kutatási kérdésem megválaszolására tehát sikerült kimutatnom, hogy az épületkonfigurációnak jelentős hatása van az energetikai és komfort teljesítményre. Ehhez meg kellett válaszolnom a 2-4 kutatási kérdéseket is, melyekkel kialakítottam egy épület reprezentációs környezetet és benne egy validációval megerősített, összes lehetőséget előállító épület konfiguráció generáló eljárást. Munkám következő lépése az 5. kérdés vizsgálata. *Helyettesíthetők-e az energetikai és komfort szimulációk kevésbé erőforrás intenzív regressziós eljárással?* Feladatomban tehát olyan adatvezérelt gépi tanuló modellt kiválasztás, létrehozása és

vizsgálata, amely alkalmas az energia és komfort értékek megfelelő pontosságú becslésére úgy, hogy figyelembe tudja venni a modulárisan tervezett épületkonfigurációt is.

Az épületkonfigurációval csak akkor végezhető informatikai művelet (pl. szimuláció vagy regresszió) ha az épület tervei elektronikus feldolgozásra alkalmas, a feldolgozó rendszerbe illeszthető formában rendelkezésre állnak. A szimulációs számításokhoz az épület háromdimenziós modelljét kellett elkészíteni. Az általam épületforma ábrázolásra használt reprezentációs keretrendszer a konfigurációk előállításával mellett a terv ilyen típusú digitalizálási folyamatát is gyorsítja. Az épület modell ugyanis az elméleti eljárást követve előállítható téglalapszerű alakú alapelemek lapok mentén történő illesztésével, majd az objektum komponensek összevonásával. A CFD szimulációkhoz használt részletes háromdimenziós modellek alkalmazása regressziós eljárásokban nem lehetséges, a regressziós eljárásokban ugyanis nehéz a folytonos geometriai alakzatot leíró változóként összefüggő halmazaként értelmezni. Ezért mindenképpen szükséges olyan épület reprezentációt találni, amelyben ábrázolva az épületkonfigurációt leíró paraméterek egy függvény leíró változói lehetnek. A moduláris térszervezés során alkalmazott, előre meghatározott tulajdonságú modulok előnye, hogy a modulok által meghatározott épületek geometriai tulajdonságai korlátozott számú diszkrét értékeket vehetnek fel. Ez lehetővé teszi speciális geometriai leírók gyakran alkalmazott arányainak gyors és egyszerű számítását, alkalmazását.

Az alábbiakban a kutatások során alkalmazott épületkonfiguráció leíró változókat mutatom be részletesen. Indirektnek nevezem azokat a leírókat, amelyek az épületforma moduláris reprezentációjából egy nem kölcsönösen egyértelmű leképezés során állnak elő. Az új ábrázolási forma azonos értékei vagy értékgyűjteményei az épületformák valamilyen energetikához kötődő, de speciális szempontú csoportosítása szerint azonosnak tekinthető elemeit jellemzi, azonban azokból a konkrét épületformák nem alakítható vissza. Direkt leíróknak nevezem azokat az ábrázolási módokat, amelyekből a konkrét moduláris épületformák egyértelműen előállíthatók.

Komplex indirekt leíró

Építészeti közelítő számítások lényeges paraméterei a hőveszteséget okozó épületfelszín és a fűtött belső térfogat. A két változó aránya [79] és a formafaktor (az épület hosszának és szélességének aránya) a leggyakrabban alkalmazott energetikai szemléletű épület leírók. Azonban megegyező fenti paraméterekkel több konfiguráció is kialakítható, így szükséges egy új, komplex leíró bevezetése. Az átviteli hőveszteség felületének és a fűtött padlótér arányának

(25) képletben bemutatott, A/S-nek nevezett kifejezését [80] az építész szakértők a 0.71 együttható bevezetésével az aktuális kutatási feladathoz szabták testre.

$$\frac{A_{env}}{S_{tot}} = \frac{A_{env-air} + A_{env-ground} \cdot 0.71}{S_{tot}} \quad (25)$$

ahol $A_{env-air}$ a tető és homlokzati elemek felszínének m^2 -ben mért felülete, $A_{env-ground}$ a talajjal érintkező vízszintes felületek (padló) m^2 -ben mért felülete, míg az S_{tot} a teljes hasznos alapterület m^2 -ben mérve.


Egyszerű indirekt leírók halmaza

Az épületet alkotó speciális geometriai elemeknek nemcsak a mérete vagy aránya vizsgálható. A moduláris térszervezés lehetővé teszi az energetikai szempontból lényegesnek vélt geometriai komponensek számának meghatározását. Mivel az épületeket alkotó modulok mérete azonos, a geometriai elemek számának összehasonlítása az arányosítással azonos hatású, de egyszerűbben kivitelezhető. Ezen gondolatmenet mentén építész szakértőink az épületkonfigurációból strukturális elemzéssel analitikusan és automatizáltan előállítható egymástól közvetlenül nem függő leírókat határoztak meg, melyeket a 3. táblázatban bemutatott csoportokba soroltak.

3. táblázat: egyszerű indirekt leírók halmaza

Felületek	Csúcsok	Élek
Padló	Konvex talajon	Talajon
Tető	Konvex tetőn	Konvex tetőn
Talaj	Konvex levegőben	Konvex levegőben
Fal		Konkáv levegőben
Tető		Konvex függőleges
		Konkáv függőleges
23.a ábra	23.b ábra	23.c ábra

Az oldalak között a 23.a ábrán bemutatott külső és belső falakat, belső födémeket, tetőt és padlót különböztettünk meg. A csúcsok közül a 23.b ábrán látható konvex csúcsok bírnak jelentőséggel, melyeket tető, talajjal érintkező külső padló és talajjal nem érintkező külső padló csoportokba sorolhatóak. Az épületen belüli födémeknek nincs energetikai hatása, ezért azok nem szerepelnek a leírók között. A 23.c ábrán az élek osztályozása látható.




23. ábra: Egyszerű indirekt leírók forrás: [77]

Az élek csoportosítását a konvex/konkáv típus (pozitív/negatív), a vízszintes/függőleges irányultság, vízszintes esetben a modul tetején/alján történő elhelyezkedés és a talajjal történő kapcsolat megléte határozta meg. Az épületforma leírására tehát 14 leszámolt változóból álló halmazt használunk.


Modul koordináták, mint direkt leírók

Az indirekt épületgeometria leírók alkalmazásának több hátránya is van. Egyrészt előállításukhoz előfeldolgozási műveleteket kell a regressziós folyamatba integrálni, ami a számítási időt és a folyamat komplexitását is növeli. Lényegesebb viszont, hogy az alkalmazott indirekt leírók kiválasztása szakértői ismeretet igényel. Mivel a regressziós folyamat előkészítése során a lényeges jellemzők kiválasztása (feature selection) nem formalizálható, a szakértők által gyakorlati tapasztalatokra, megérzésekre alapozott választás hatékonysága nem igazolható. A hibás választás a regressziós modell pontosságának vizsgálatakor valószínűsíthető, azonban nem lehet egyértelműen következtetni a leírók és/vagy a modell alkalmatlanságára. Továbbá, a leírók alkalmatlansága esetén nincs iránymutatás a megfelelő leírók kiválasztására.

Ezért vizsgálni kell a regressziós modell feature szelekciós képességét. Ebben segítségemre van a modell struktúrájának és működésének ismerete. Amennyiben a modell képes a leíró változók komplex összefüggéseinek vizsgálatára, a megoldás elkészítésének szempontjából célravezető a leíró változókat nyers formában a modell tanító eljárásának rendelkezésére bocsátani és hagyni, hogy az a modellt úgy alakítsa ki, hogy tartalmazza a megoldás szempontjából leginkább hasznos összefüggések meghatározását. Ez a hozzáállás azért is fontos, mert meglehet, hogy a leíró változók megoldáshoz felhasznált leginkább informatív összefüggése a szakértők számára nehezen, vagy egyáltalán nem értelmezhető, ezáltal előzetes megfogalmazásuk is nehezen, vagy egyáltalán nem lehetséges.



(a) Modulok



(b) Modul koordináták

24. ábra: Modulok a 3D térben


Ezért a regressziós modelljeim bemeneteként felhasználok a modulok olyan diszkrét ortogonális bázisú koordináta-rendszerben meghatározott koordinátáit, amelyben a bázisok egységei a modul megfelelő tengely mentén mérhető méretei. Mivel a validációs eljárás csak a modulok átfedés nélküli elhelyezését teszi lehetővé, az alkalmazott koordináták 0 alapú pozitív egész számok, hiszen az előre meghatározott méretű, **Moduláris térszervezés alapú konfiguráció tervezés** fejezetben bemutatott keresési térünket az origóból indulva a tengelyek pozitív tartományába feszítjük ki. Az egyes modulok koordinátái tehát a modul origóhoz legközelebbi pontjának (24.b ábra) koordinátái lesznek.

A háromdimenziós ábrázolás esetén így a konfigurációt leíró változók száma (modulszám * 3) az aktuális kísérletben 18 db leíró változó alkalmazását jelenti.

Keresési tér funkcionális pontfelhője

A modulkoordináta direkt leíróként történő alkalmazása a feature létrehozási, kiválasztási eljárást támogatja, azonban nagy korlátozást jelent a blokkok, így koordináták előre meghatározott száma. Ugyanis a bemenő változók száma a gépi tanuló rendszerek olyan paramétere, melynek változtatása új modell kialakítását és tanítását igényli. Ki kell tehát alakítanom egy olyan épületkonfiguráció leírót, amelyben az alkalmazott építőelemek számának, esetleges funkciójának módosítása nem okoz strukturális változást.

Ezt teszi lehetővé a modulkoordináták kiterjesztése a teljes keresési tér modulokkal diszkrétizált, funkcionális reprezentációjára.



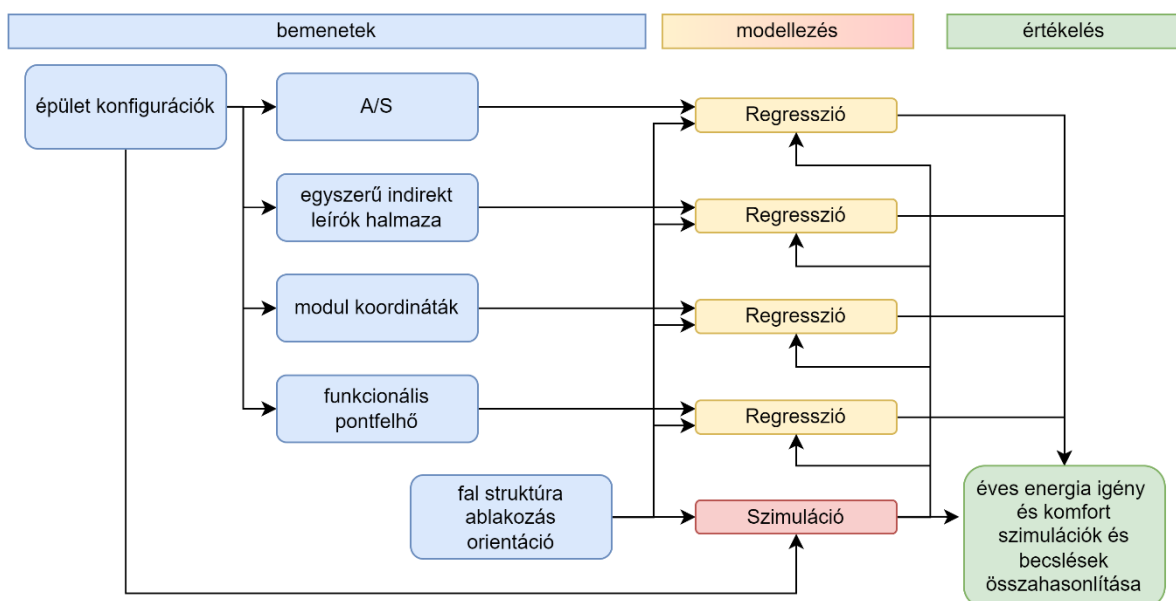
25. ábra: Épületkonfigurációt ábrázoló funkcionális pontfelhő

A 25. ábra funkcionális pontfelhőjében szereplő funkció leírók a modul koordinátákhöz hasonlóan az adott koordinátán kezdődő, attól mindhárom tengely mentén pozitív irányba növekvő, modul méretű és formájú térfogatrész funkcióját jelöli. Az aktuális kísérletben két funkciót különböztettem meg: épület (piros, egész 1 érték) és épületen kívüli, szabad tér (szürke, egész 0 érték).

Surrogate modellek - szimulációk regressziós közelítése

Az 5. kutatási kérdésünk megválaszolásához, adatvezérelt gépi tanuló eljáráson alapuló regressziós modell készítéséhez rendelkezésre áll már a konfiguráció reprezentációs leíró rendszer, benne a lehetséges épületkonfigurációk két indirekt és két direkt kódolással és azok paraméteres szimulációi.

A 26. ábra mutatja be a javasolt regressziós modell készítésének folyamatát.



26. ábra: Modell készítés és értékelés folyamata

A modellkészítéshez leíró változónak felhasználok az épület konfigurációk indirekt és direkt kódolású reprezentációit, valamint a további lényeges építészeti paramétereket (falstruktúra, fal-ablak arány, főhomlokzat orientáció). A leíró változókhoz tartozó függő változók a megfelelő paraméter beállításokkal számított energetikai és komfort szimulációk lesznek. Az előállított modellek értékelését a függő változó kapott és elvárt értékeinek összehasonlításával végezzük.

Lineáris regresszió

Ahogy már a [77], [78] munkákban is írtunk róla, a regressziószámítás egy széles körben, így az építészeti szimulációkban is gyakran használt [36] [37], [38], [39], [40] statisztikai eljárás, mely azt igyekszik meghatározni, hogy egy függő változó milyen módon függ a leíró változóktól.

A többváltozós lineáris regresszió[81], [82] az általános regressziószámítás speciális esete, amikor a függő változó a leíró változók lineáris kombinációjaként, az (26) képletben bemutatott módon, elsőrendű Taylor-sorral áll elő.

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + \varepsilon \quad (26)$$

$$h(x) = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n \quad (27)$$

$$\varepsilon = y - h(x) \quad (28)$$

ahol y a függő változó, $x_1 \dots x_n$ a leíró változók, $\beta_0 \dots \beta_n$ a lineáris regressziós modell paraméterei, $h(x)$ a lineáris regresszió hipotézis függvénye, ε pedig a lineáris regresszió közelítési hibája.

A (27) képletben bemutatott hipotézisem szerint található olyan $\beta_0 \dots \beta_n$ paraméter gyűjtemény, amely felhasználásával készített lineáris regressziós modell (28) képlettel leírt hibája egy szakértők által is elfogadható küszöb alatt marad.

A megoldásra alkalmazott adatvezérelt eljárás nevét onnan kaptam, hogy a paraméterek meghatározásához a leíró- és függő változók több független megfigyeléséből összeállított $(x_1 \dots x_n, y)$ minták statisztikai elemzését használja. A (27) képlet β paramétereinek meghatározásához a legkisebb négyzetek analitikus módszerét [81] alkalmaztam.

Többváltozós lineáris regressziós modell kialakításakor feltételeztem, hogy a függő változót több (m darab) leíró változó határozza meg. Ekkor a leíró változók egyes (n darab) megfigyelésekhez tartozó értékeit egy n sorból és m oszlopból álló

$$\mathbf{X}_o = \begin{bmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{bmatrix} \quad (29)$$

mátrixba gyűjthető, ahol n a megfigyelések, m pedig a leíró változók száma, így a mátrix x_{ij} eleme az i -edik megfigyelés j -edik leíró változóját jelenti.

A függő változó egyes megfigyelésekhez tartozó (n darab) értékei a (30) képletben bemutatott \mathbf{y} oszlopvektorba, a (27) egyenlet β paraméterei (m darab) pedig a (31) képletben leírt $\boldsymbol{\beta}$ oszlopvektorba gyűjthetők.

$$\mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \quad (30)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \vdots \\ \beta_m \end{bmatrix} \quad (31)$$

Ahol y_i az i -edik megfigyelés függő változója, β_j a j -edik leíró változó együtthatója. Vegyük észre, hogy az \mathbf{X}_o mátrix első oszlopindexe 1, míg a β vektor első sorindexe nulla (0). A (27) felhasznált konstans paraméter (β_0) leíró változókkal azonos kezeléséhez bővítjük a leíró adatokat egy konstans 1 értékű leíróval. Ekkor az \mathbf{X}_o mátrixot egy konstans 1-eket tartalmazó első oszloppal bővül.

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{nm} \end{bmatrix} \quad (32)$$

A fenti jelölések (30)-(32) felhasználásával a lineáris regressziós modell a (33) mátrix formába írható:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (33)$$

ahol $\boldsymbol{\varepsilon}$ az egyes megfigyelések lineáris regressziójának közelítési hibáiból összeállított oszlopvektor, melynek ε_i eleme az i -edik megfigyelés közelítési hibája található.

A $\boldsymbol{\beta}$ paraméter vektor meghatározásához, ahogy korábban említettem, az m ismeretlen lineáris egyenletrendszer a legkisebb négyzetek módszerével oldjuk meg. Ekkor a paraméter vektort az (34) képletben leírtak alapján kapjuk.

$$\tilde{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} \quad (34)$$

A paraméter vektor felhasználásával a lineáris regressziós modellünk becslése a (35) szerint írható fel.

$$\tilde{y} = \mathbf{x}\tilde{\boldsymbol{\beta}} \quad (35)$$

ahol \mathbf{x} a leíró változók egy becslést igénylő beállítását tartalmazó sorvektor, \tilde{y} pedig a modell által előállított közelítő érték. A lineáris regressziós közelítés abszolút hibája pedig (36) egyenlettel számítható.

$$\varepsilon_a = |y - \tilde{y}| \quad (36)$$

Polinomiális regresszió

A lineáris regresszió általános alkalmazása abba az erős korlátba ütközik, hogy a leíró és függő változóknak csak lineáris összefüggését képes jól közelíteni. A lineáris közelítés hatékonysága tehát olyan leírók kiválasztásán múlik, melyek lineáris kombinációja jól közelíti a függő változó értékét. Ez az **Épületkonfiguráció leírók** fejezetben korábban említett okok miatt is nehezen megoldható. Kihaszználható azonban az, hogy a lineáris regresszió nem tartalmaz megkötést a leíró változók függésére. Így a nemlineáris közelítés támogatására a leíró változók halmaza az eredeti leíróktól erősen függő változókkal bővíthető. Mivel a bevezetett változók az eredeti változókhoz hasonlítva nem hordoznak új információt, csak a függés jellegét változtatják meg, a keresési tér dimenzióját nem, így a mintaadatok relatív felbontását nem csökkentik. A hozzáadott változók az eredeti leírók multiplikatív kombinációiként állíthatók elő, meghatározott maximális hatványig. A (37) képletben két leíró változó legfeljebb harmadik hatványú szorzat kombinációit tartalmazó polinomfüggvény látható.

$$f(x_1, x_2) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1^2 + \beta_4 x_1 x_2 + \beta_5 x_2^2 + \beta_6 x_1^3 + \beta_7 x_1^2 x_2 + \beta_8 x_1 x_2^2 + \beta_9 x_2^3 \quad (37)$$

Ez a felső hatványkorlát lényeges a regressziós modell szempontjából, ugyanis növelése (38) képlet és a 4. táblázat szerint növelheti a modell bemenő változóinak számát, így a komplexitást és a paraméterek meghatározásának idejét is. A modellkészítés során tehát a felső hatványkorlátot a lehető legkisebb értéken szükséges tartani. Ebben a következő fejezetben bemutatott regularizáció lehet gyakorlati segítség.

$$\tilde{M} = \sum_{p=1}^P C_{N+p-1}^{p,r} = \sum_{p=1}^P \frac{(M+p-1)!}{p!(M-1)!} \quad (38)$$

A (37) képletben szereplő M a leíró változók kezdeti darabszáma, P a felső hatványkorlát. A leíró változók halmazának bővítése nélkül azok első hatványon szerepelnek, így darabszámuk megegyezik az \tilde{M}_1 értékével.

4. táblázat: Az alkalmazott leírók változók száma a darabszám és a hatványkorlát szerint

M	Hatvány (P)	Független	A/S	14 egyszerű	Koordináták	Pontfelhő
$M=\tilde{M}_1$	1	3	1+3	13+3	18+3	75+3
\tilde{M}_2	2	9	14	152	252	3081
\tilde{M}_3	3	19	34	968	2023	85319

Regularizáció

Az előző fejezetben a nemlinearitás biztosítása érdekében jelentősen növelni kellett a modell bemenő változóinak számát, ezzel a modell komplexitását. A regularizáció alkalmazásának célja az elkészített modell lehető legegyszerűbben tartása. Ennek érdekében a költségfüggvényt a bemenő változók együtthatóinak abszolút értékével arányos büntetéssel szükséges bővíteni. Így az optimalizáció az együtthatók keresése során a 0-hoz közeli értékeket részesíti előnyben. A 0 súlyú bemenetek a kimenet szempontjából érdektelenek, azokkal a rendszer egyszerűsíthető.

A kutatásokban használt regularizációs technikák:

- A (39) képletben leírt Least Absolute Shrinkage and Selection Operator – LASSO (L1) [42], [43], melynek célja a lehető legtöbb bemenő változó eltávolítása, vagyis súlyának 0-ra csökkentése.

$$E_{LASSO} = \sum_{i=1}^N (y_i - \bar{\beta}^T \bar{X}_i)^2 + \lambda \sum_{j=1}^M |\beta_j| \quad (39)$$

- A (40) képletben bemutatott Ridge (L2) [44], [45], eljárás, melynek célja a bemenő változók hatásának csökkentése

$$E_{Ridge} = \sum_{i=1}^N (y_i - \bar{\beta}^T \bar{X}_i)^2 + \lambda \sum_{j=1}^M \beta_j^2 \quad (40)$$

Modellek értékelése

Az egyes adatelemek becslésének értékelésére a (41) képletben leírt átlagos abszolút és az (42) képletben leírt átlagos négyzetes hibát használtam.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (41)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (42)$$

A modellek értékelésére az abszolút és négyzetes hiba mellett alkalmaztam még, a becsült érték arányában kifejezett, a (43) képletben bemutatott átlagos relatív hibát és annak (44) képletben bemutatott abszolút értékét.

$$\varepsilon_r^* = \frac{\sum_{i=1}^n \frac{(y_i - \tilde{y}_i)}{y_i}}{n} \quad (43)$$

$$MAPE = \frac{\sum_{i=1}^n \frac{|y_i - \tilde{y}_i|}{y_i}}{n} \quad (44)$$

A statisztikában és a regresszió analízisben széles körben alkalmazott, (45) képletben bemutatott R^2 pont [83] metrika leírja, hogy a függő változó varianciájára milyen hatással vannak a leíró változók. Vagyis a variancia mekkora része származhat a leíró változók varianciájából. A képletben szereplő y a közelítendő, \tilde{y} a közelítő, \bar{y} az átlagos közelítendő értékeket jelölik.

$$R^2 = 1 - \frac{a \text{ becslés varianciája}}{a \text{ becsült adatok varianciája}} = 1 - \frac{\sum (y - \tilde{y})^2}{\sum (y - \bar{y})^2} \quad (45)$$

Az R^2 mérték szerint elérhető legjobb eredmény az 1, az alacsonyabb értékek rosszabb teljesítményt jelentenek és elérhető negatív érték is.

A becslések megbízhatósága

A becslésekhez tartozó konfidencia intervallumok meghatározásához a normális eloszlás σ szabályait alkalmaztam. Ehhez szükséges a (46) képletben leírt variancia és a (47) képletben bemutatott szórás meghatározása.

$$Var = \frac{1}{N} \sum_{i=1}^N (\tilde{y}_i - \hat{y})^2 = \frac{1}{N} \sum_{i=1}^N \left(\tilde{y}_i - \frac{1}{N} \sum_{j=1}^N \tilde{y}_j \right)^2 \quad (46)$$

$$\sigma = \sqrt{Var} \quad (47)$$

Normális eloszlás esetén a statisztikában gyakran alkalmazott σ szabályok leírják, hogy a valószínűségi változó értékei milyen valószínűséggel lesznek a μ átlag (48) képlet egyszeres, (49) képlet kétszeres vagy (50) képlet háromszoros szórásának környezetében.

$$\Pr(\mu - 1\sigma \leq X \leq \mu + 1\sigma) \approx 68,27\% \quad (48)$$

$$\Pr(\mu - 2\sigma \leq X \leq \mu + 2\sigma) \approx 95,45\% \quad (49)$$

$$\Pr(\mu - 3\sigma \leq X \leq \mu + 3\sigma) \approx 99,73\% \quad (50)$$

A becslés pontosságát normális eloszlású valószínűségi változóként vizsgálva a szabályok felhasználásával kijelenthetjük, hogy a becslésünk hibája (51) képletben bemutatott várható szerint alakul az esetek 95%-ában.

$$\text{Várható hiba} < \max(|\text{átlag} - 2 \cdot \sigma|, |\text{átlag} + 2 \cdot \sigma|) \quad (51)$$

A szigmaszabályok azonban csak normális eloszlású valószínűségi változón használhatók, így vizsgálnom kellett, hogy a becslésünk hibája normális eloszlást követ-e. Az illeszkedésvizsgálathoz az alábbi statisztikai tesztekkel használtam:

- Shapiro-Wilk [84]
- D'Agostino's K^2 [85]
- Anderson – Darling [86]
- Kolmogorov – Smirnov [87]

Az illeszkedésvizsgálati eredmények azt mutatták, hogy az abszolút hiba nem, azonban a százalékos hiba közel normális eloszlású.

Mivel a tesztek ezt nem igazolták egyértelműen, a nem normális eloszlások a megbízhatósági intervallumait az 1. és 3. kvartilis közötti távolsággal (Inter Quartile Range – IQR) [88], [89] fejeztem ki. Vizsgálataim tehát kiterjedtek a teljes adatsor mediánjának és az adatsor felső és alsó feléből választott mediánok, az 1. és 3. kvartilisek, meghatározására, majd azok felhasználásával az (52) képlet alapján számított IQR számítására is.

$$IQR = Q_3 - Q_1 \quad (52)$$


$$\Pr(Q_1 \leq X \leq Q_3) \approx 50,0\% \quad (53)$$

$$\Pr(Q_1 - 1,5 \cdot IQR \leq X \leq Q_3 + 1,5 \cdot IQR) \approx 99,3\% \quad (54)$$

Az (53) és (54) képletek bemutatják az IQR-ből képzett megbízhatósági intervallumok statisztikai jellemzőit. Ez alapján az első és harmadik kvartilis közé várhatóan a minták 50%-a

esik, míg a $Q_1 - 1,5 \cdot IQR$ és $Q_3 + 1,5 \cdot IQR$ közé eső tartományba várhatóan 99,3%. Tehát az interkvartilis távolság alapú $4 \cdot IQR$ megbízhatósági tartomány valószínűleg tartalmazza a minták 99%-át.

A szórás és az IQR alapján számított megbízhatósági intervallumok összefüggését a 27. ábra szemlélteti.




27. ábra: IQR és szórás összefüggése

Kép forrás: wikipedia (https://en.wikipedia.org/wiki/Interquartile_range)

A vizsgálatok során a regressziós eljárások elfogadásához megbízhatósági intervallumnak az építész szakértők a második, 99,3%-os valószínűségű tartományt választották, így a várható pontosságot ehhez a szinthez határoztuk meg.


A relatív hiba átlagából és szórásából a normális eloszlás 3σ szabályát felhasználva a becslési hibák valószínűségei közelíthetők. A várható hibaintervallumot mutató 5. ábra tendenciája az előállításból fakadóan egyezik a szórás tendenciájával. Ez alapján kijelenthetem, hogy az első 3 modell esetében a (normális hibaeloszlás esetén) a becslések 99.9%-a a becsült érték körüli 16%-os tartományon belül tartható.



28. ábra: A relatív közelítési hiba intervalluma ($|\bar{y}| + 3\sigma$) [%]

Lineáris regressziós eredmények

A véletlen választásnak a modellek hatékonyságára gyakorolt hatását a későbbiek folyamán részletesen vizsgálom. Most ennek a hatásnak a csökkentése érdekében minden modelltől véletlen alapú tanító-tesztelő mintaválasztásokkal 10-10 darabot készítettem. A 27. ábra minden oszlopában a 10 azonos típusú bemenetet alkalmazó modell abszolút hibaátlagát szemléltettem.




27. ábra: Lineáris regresszió átlagos abszolút pontossága

A 27. ábráról leolvasható, hogy a jó épületkonfiguráció leíróval és a bemenő változók megfelelő kiegészítésével a legjobb elérhető átlagos pontosság 106Wh/évfűtési energiaigény. Ez a 2.


táblázat első sorában szereplő legkisebb éves energiaigénynek (5486kWh/év) is mindössze a 1,9%-a. Az alkalmazott épületkonfiguráció leíró és lineáris regressziós modell kapcsolatát vizsgálva azt is kijelenthetem, hogy a többváltozós lineáris regresszió direkt épületkonfiguráció leírók legfeljebb harmadik kitevőjű hatványával adja a legjobb közelítést. Mivel sem az L1, sem az L2 regularizációnak nincs pontossági haszna, a modell komplexitása az optimális közelében lehet.

Az átlagos 106kWh/év abszolút hiba a szakértők számára elfogadhatónak tűnik, de a közelítés hibájának pontosabb megítéléshez az abszolút hibát a becsült érték arányában is vizsgáltam. A MAPE alakulását a 28. ábra mutatja. Abból és az 5. táblázatból kiolvasható, hogy az elérhető legjobb átlagos százalékos hiba a közelített érték 1%-a körül marad. A két mértéket figyelembe véve az építész szakértők elfogadták a regressziós eljárást, ez alapján kijelenthetem, hogy az épület fűtési energiaigény szimulációja helyettesíthető megfelelően paraméterezett többváltozós lineáris regresszióval.



28. ábra: Lineáris regresszió átlagos abszolút százalékos pontossága

A 29. ábrán látható R^2 pont leírja a függő változó varianciáját milyen mértékben határozzák meg a leíró változók. A legmagasabb összefüggést a regularizáció nélküli, direkt leírók legfeljebb harmadik hatványait használó polinomiális regresszió alakította ki.



29. ábra: Lineáris regresszió R^2 pontossága

Az adatok vizsgálata alapján belátható, hogy az épületkonfigurációs leíró nem használó lineáris regresszió jelentősen rosszabbul, hatszor nagyobb átlagos abszolút és átlagos abszolút százalékos hibával közelítette a szimulációs adatokat, mint az épületkonfigurációs adatokat használó. Az R^2 pont így 0.99-ről 0.73 köré csökkent. Vagyis az épületkonfiguráció leíró használata jelentősen javítja a pontosságot és erősíti a leíró és függő változók kapcsolatát. Ez megerősíti az első kutatási kérdésünk megválaszolására létrehozott hipotézisünk igazolását.

A 28. ábra adatai az 5. táblázatba részletesen is áttekinthetők, ahonnan könnyen és pontosan leolvasható, hogy a 14 egyszerű indirekt leíró és a direkt leírók teljesítettek legjobban, azonos átlagos 1% pontosságot mutattak.

5. táblázat: Különböző bemenetekkel készített lineáris regressziós modellek átlagos abszolút százalékos hibái

Modell	Épület konfiguráció leíró nélkül		
	1. hatvány	2. hatvány	3. hatvány
LR	0,09	0,07	0,06
	0,08	0,07	0,06
LR _{LASSO}	0,09	0,07	0,06
	0,08	0,07	0,06
LR _{Ridge}	0,09	0,07	0,06
	0,09	0,06	0,06

Modell	A/S			14 egyszerű indirekt leíró		
	1. hatvány	2. hatvány	3. hatvány	1. hatvány	2. hatvány	3. hatvány
LR	0,07	0,03	0,02	0,07	0,02	0,01
	0,05	0,03	0,02	0,05	0,02	0,01
LR _{LASSO}	0,07	0,03	0,03	0,07	0,02	0,01
	0,05	0,04	0,03	0,04	0,02	0,01
LR _{Ridge}	0,07	0,03	0,02	0,07	0,02	0,01
	0,05	0,03	0,02	0,04	0,02	0,01
Modell	blokk koordináták			funkcionális pontfelhő		
	1. hatvány	2. hatvány	3. hatvány	1. hatvány	2. hatvány	3. hatvány
LR	0,07	0,03	0,01	0,07	0,02	0,01
	0,09	0,04	0,01	0,06	0,02	0,01
LR _{LASSO}	0,07	0,03	0,02	0,07	0,02	0,01
	0,05	0,03	0,02	0,06	0,02	0,01
LR _{Ridge}	0,07	0,03	0,01	0,07	0,02	0,06
	0,09	0,04	0,02	0,06	0,02	0,06

A vizsgált adatok alapján az ötödik kutatási kérdésemre is megtaláltam a választ, vagyis a környezet megfelelő leírót használó és megfelelő paraméterekkel rendelkező polinomiális regressziós eljárás alkalmas a komplex épület energetikai szimulációk helyettesítésére.

A továbbiakban tehát a hatodik kutatási kérdésnek megfelelően azt vizsgáltam, hogy melyik regressziós modell típus és milyen speciális struktúrában a legmegfelelőbb az energetikai és komfort szimulációk helyettesítésére. Ezért vizsgálataimat a döntési fa és a neurális hálózat alapú regressziós modell típusokra is kiterjesztettem.


Regressziós döntési fa

A regressziós feladat megoldására alkalmazott döntési fa alapú modellek [46] a függő változó értékét vagy értéktartományát a leíró változók értékeinek ismételt vizsgálatával állítják elő. A modellt leíró fagráf, amiről a módszer a nevét is kapta, levél csomópontjai a függő változó becsült értékei, vagyis a kimeneti becslések. A fagráf belső csomópontjai pedig a döntések, amelyekben egyszerre egy leíró változó egy konkrét vizsgálatát (küszöbölését) kell elvégezni.

A döntési fa alapú regresszió tehát egy dinamikus osztályozási eljárás, melyben az osztályok számát és intervallumait az algoritmus dinamikusan határozza meg úgy, hogy a közelített teret rekurzívan alterekre bontja és az egyes altereket konstans értékekkel, az alterek intervallumainak, vagy az altérbe sorolt elemek értékeinek átlagával, esetleg az adott altérbe sorolt leggyakoribb elemmel közelíti.

A 30. ábrán egy harmadfokú zajos példafüggvény döntési fával történő közelítése látható. Az ábrán a fa által generált (legfeljebb 16) kimeneti érték szintje jól elkülöníthető, közöttük a

vizualizáció érdekében lineáris interpolációt alkalmaztam. Az egyes közelítő értékek meghatározásához készített döntési fa gyökér csomópontból történő bejárása tehát a mintatér rekurzív részterekre bontását jelenti addig, amíg a felosztás a becsléshez új elemet ad (pontosítja azt), vagy a résztér már nem bontható további részterekre.



30. ábra: Harmadfokú zajos példa függvény közelítése 4 szint mély döntési fával

A döntési fa kialakításának kulcsa a belső csomópontok, vagyis az alkalmazandó felosztások paramétereinek meghatározása, ami a leíró változó és a döntési határérték kiválasztását jelenti. Regressziós döntési fák esetében ezt a választást a felosztás utáni alterek varianciáinak (55) képletben bemutatott minimalizálásával,

$$\text{argmin: } error_{left} + error_{right} \quad (55)$$

vagy más szóval (56) képletben bemutatott variancia nyereség maximalizálásával végzik.


$$\text{gain} = \frac{error_{parent}}{N_{parent}} - \left(\frac{error_{left}}{N_{left}} + \frac{error_{right}}{N_{right}} \right) \quad (56)$$

A variancia mérésre az alábbi eljárásokat választottam:

- L1 távolság mértéken alapuló, (41) képletben korábban bemutatott átlagos abszolút hiba (MAE)
- L2 távolság mértéken alapuló, (42) képletben bemutatott átlagos négyzetes hiba (MSE)

Az alkalmazott hiba mértékek karakterisztikáit a 31. ábra szemlélteti. Az egyes távolság mértékek karakterisztikája, amely befolyásolja a minimalizálási feladat megoldását.

A 30. ábrán bemutatott feladat regressziós megoldását előállító döntési fa grafikus megjelenítése a 32. ábrán látható.



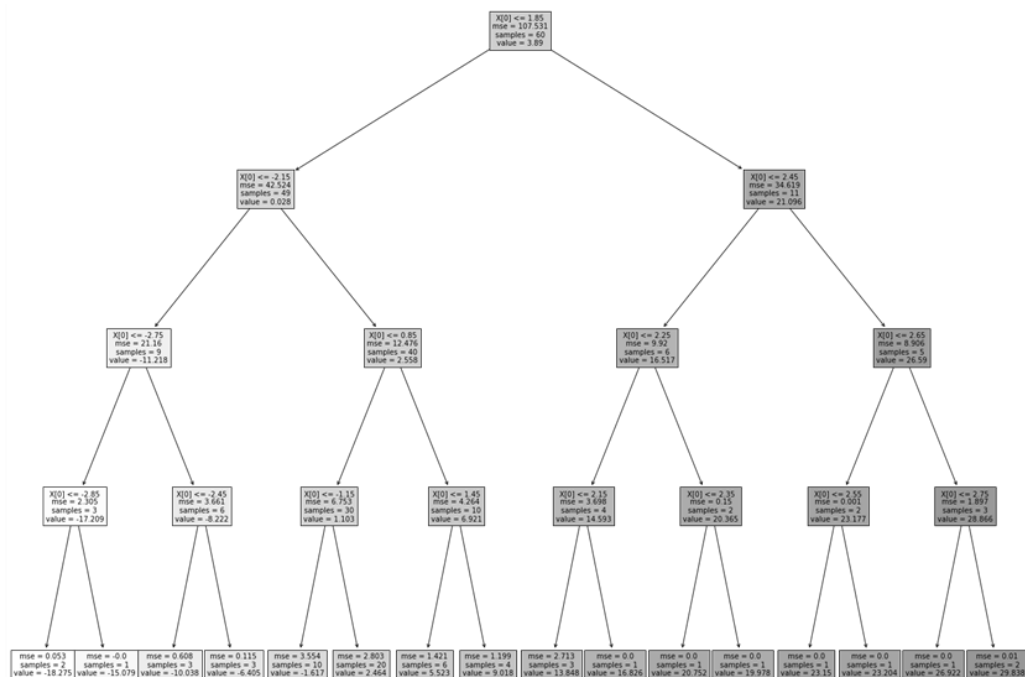
31. ábra: A távolság mértékek karakterisztikájának különbsége

A döntési fák alkalmazásának előnyei:

- képes nemlineáris függvény közelítésére is
- mohó algoritmus is jó közelítést ad
- egyszerű algoritmus
- gyors futás – alacsony erőforrásigény
- lehetséges a kialakuló döntési fa szakértői értelmezése

Hátrányai:

- nem robusztus – érzékeny a tanító adatok változására
- az optimális fa elkészítése NP-teljes
- fennáll a túlilleszkedés veszélye, vagyis a túl komplex fa előállításának esélye




32. ábra: Harmadfokú zajos példa függvény közelítését végző 4 szint mély döntési fa

Regressziós neurális hálózat

Az idegrendszer felépítése által ihletett, az univerzális közelítési tételben megfogalmazott számítási modellen alapuló közelítő eljárás [55].

Struktúráját tekintve önálló, analóg feldolgozó műveletet végző egységek rétegekbe szervezése a 33. ábra szerint. Az első réteget bemeneti, az utolsót kimeneti rétegnek nevezzük. A bemeneti és kimeneti rétegek között tetszőleges számú rejtett réteg helyezkedhet el. Az egymást követő rétegek elemei között teljes a kapcsolat, azonban egy rétegen belül, vagy távolabbi rétegek elemei nem állnak egymással kapcsolatban. A bemeneti réteg feladata a hálózat bemenetére érkező adatok fogadása és a megfelelő, feldolgozható formátumba alakítása. A rejtett rétegek feladata a kimenet előállításához szükséges speciális jellemzők előállítása, a kimeneti réteg feladata pedig a megfelelő formátumú kimenet előállítása.




33. ábra: Teljesen előrecsatolt neurális hálózat

Az ábrán M a bemeneti jellemzők száma, azonos a bemeneti réteg neuronjainak számával, H_1 és H_2 a rejtett rétegek neuronjainak száma, amely a rétegenként eltérhet. O a kimeneti neuronok száma, amely a regressziós feladatok megoldása során $O = 1$, hiszen a rendszer egy folytonos értéket közelít.

Az egyes feldolgozó elemek sematikus felépítését az 34. ábra mutatja be. A cellák, vagy más néven neuronok első lépésként előállítják a bemeneteik súlyozott összegét, majd egy aktivációs függvény felhasználásával előállítják a kimenetüket. Aktivációs függvénynek tetszőleges függvény választható, azonban a konkrét megoldandó feladat és a tanító eljárás megfelelő működése érdekében speciálisan kialakított függvények közül választottam.

Egyszerűsített struktúrában, ha a hálózat nem tartalmaz rejtett réteget, valamint a kimeneti rétegben egy, lineáris aktivációt alkalmazó neuron található, akkor lineáris regressziós megoldás áll elő. Azonban a lineáris feldolgozást végző elemek többrétegű kapcsolatával és

nemlineáris aktiváció alkalmazásával az univerzális közelítési tételben leírt módon nemlineáris művelet is elvégezhető.



34. ábra: Mesterséges neuron sematikus ábrája

Jelenleg nem áll rendelkezésre a hálózat struktúráját meghatározó analitikus eljárás, a megfelelő szerkezet kiválasztása a tanítási és általános képességek értékelését végző lépések statisztikai elemzésére, összehasonlítására támaszkodik.

A hálózat tanítása

A modell kialakítása során a feladat a kapcsolatot leíró paramétereinek meghatározása a mintaadatok alapján. Vagyis a (57) képlet J négyzetes átlagos hiba (MSE) alapú költség függvényének minimalizálásával θ paraméterek mentén.

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h(x^{(i)}) - y^{(i)})^2 \quad (57)$$

$$\theta_j^{k+1} = \theta_j^k - \alpha \frac{\partial J(\theta)}{\partial \theta_j} \quad (58)$$

A paraméterek optimális meghatározására használható a **csökkenő gradiens** (gradient decent) [90] módszer. Ennek lényege, hogy a paramétereket valamilyen kezdőértékkel inicializáltam, majd a (58) képlet alapján a k -ról a $k+1$ lépésre úgy módosítottam azokat, hogy a költségfüggvény csökkenjen, végül egy remélhetőleg globális minimumban állapodjon meg. A csökkentést a költségfüggvény gradiense mentén végeztem. Ez azt jelenti, hogy vizsgáltam a paraméterek által aktuálisan leírt függvényhelyet, és kiválasztottam egy megfelelően kicsi lépésnek azt az irányát, amivel a költségfüggvény értéke csökken. A lépés irányát a költségfüggvény aktuális paraméterek által meghatározott pontjába húzott érintő egyenesszöge (csökkenésének iránya) határozta meg. Az egyes paraméterek változtatásához a költségfüggvény adott paraméterek szerinti parciális differenciálhányadosait használtam,

hiszen ezek tükrözik az adott paraméterek költségfüggvényre gyakorolt hatását. A csökkenő gradiens módszere tehát úgy hajtja végre a paraméterek módosítását, hogy a csökkenő gradiens mentén megtett megfelelően kicsi lépésben a költségfüggvény értéke csökkenjen. Azonban a **megfelelően kicsi** lépés méretének meghatározása nem könnyű feladat. A (58) képletben a lépés méretét α jelöli és a gépi tanulásban tanulási rátának (learning rate) nevezik. A tanulási ráta határozza meg a konvergencia sebességét. Minél nagyobb a tanulási ráta, annál gyorsabb lesz a minimum közelítése. Túl kicsire választott lépésköz esetében a konvergencia lassú, a minimum közelében nehezen azonosítható lesz. A költségfüggvény alakjától függően azonban a túl nagyra választott tanulási ráta a minimumtól távoli oszcillációt vagy rossz esetben divergenciát okozhat. A *gradient decent* algoritmusban megfelelő tanulási ráta tapasztalati úton történő megválasztása mellett nagyon lényeges kérdés a paraméterek kiindulási értékének tárgyalása is. Ugyanis az eljárás parabolikus költségfüggvény esetén megfelelő tanulási rátával bármely kiindulási pontból a minimumba visz. Nem parabolikus költségfüggvények esetében más a helyzet. Ekkor a függvénynek több minimum értéke is lehet, melyek közül nem mindegyik globális minimum. A kiindulási helytől függően az algoritmus más minimumba vezethet, vagyis találhat lokális vagy globális minimumot. A minimum érvényességének meghatározására pedig nincs mód. Amennyiben a kapott eredmény nem felel meg az elfogadási feltételeknek, másik megoldás kereshető a paraméterek másik kezdőértékének meghatározásával. Ezért az eredmények stabilitását a későbbiekben külön ellenőrzöm.

Természetesen a *gradient decent* algoritmus helyett más minimumkereső eljárást is [91] alkalmazhattam volna, melyek előnye lehet a tanulási ráta kézi meghatározásának mellőzése, a sebesség, a keresési tér jobb bejárása. Ilyenek például:

- Conjugate gradient [92], [93]
- BFGS algorithm [94], [95]
- Limited memory BFGS [96]
- Stochastic gradient decent [97], [98], [99]

A lineáris regresszióban több leíró változó, így több paraméter is használható. A gépi tanuló modell szempontjából a leíró változók között fennálló esetleges összefüggés lényegtelen, a változókat a modell tulajdonképpen függetlenként kezeli. Ekkor az egyes leíró változókhoz saját együtthatók (θ paraméterek) tartoznak, vagyis az optimalizálás több paraméter párhuzamosan mentén történik.

Bemenet vagy belső struktúra bővítés

A neurális hálózatokról ismert, hogy rejtett rétegek feladata a probléma megoldásához szükséges speciális összefüggések meghatározása tanulással. Így képesek lehetnek nemlineáris összefüggések meghatározására is.

Felmerül tehát a kérdés, hogy a megoldás nemlinearitását a bemenetek vagy a hálózat bővítése, esetleg a két lehetőség kombinációja adja.

- A neurális hálózat bemenetszámának eggyel növelése, vagyis a bemeneti rétegének egy neuronnal történő bővítése a teljes rendszer paramétereit az első rejtett réteg felé irányuló H_1 súllyal bővíti, vagyis a rendszerbe H_1 új paraméter kerül
- A neurális hálózat bemeneteinek legfeljebb p hatványú szorzatkombinációra emelése a bemenetek M számát az ismétléses kombináció felhasználásával (59) egyenlet szerint \tilde{M} -ra változtatja. Az új bemenetek mindegyike csatlakozik az első rejtett réteg minden feldolgozó egységéhez. Így a rendszer paramétereinek száma a (60) egyenletben leírtakkal változik

$$\tilde{M}_P = \sum_{p=1}^P \bar{C}_M^p = \sum_{p=1}^P C_{M+p-1}^p = \sum_{p=1}^P \frac{(M+p-1)!}{p!(M-1)!} \quad (59)$$

$$C_{M+p-1}^p H_1 = \frac{(M+p-1)!}{p!(M-1)!} H_1 \quad (60)$$

- Egy rejtett réteget tartalmazó neurális hálózat rejtett rétegének egy neuronnal történő bővítése a teljes rendszer paramétereit az új neuron bemeneti rétegről érkező M db bemeneti és a kimeneti réteg felé induló 1 kimeneti súlyával bővíti, vagyis a rendszerbe összesen $M+1$ új paraméter kerül.
- Két rejtett réteget tartalmazó hálózat első rejtett rétegének egy neuronnal történő bővítése a teljes rendszer paramétereit az új neuron bemeneti rétegről érkező M db bemeneti és a második rejtett réteg felé induló H_2 kimeneti súlyával bővíti, vagyis a rendszerbe összesen $M+H_2$ új paraméter kerül.
- Két rejtett réteget tartalmazó hálózat második rejtett rétegének egy neuronnal történő bővítése a teljes rendszer paramétereit az új neuron előző rejtett rétegből érkező H_1 db bemeneti és a kimenő réteg felé induló 1 kimeneti súlyával bővíti, vagyis a rendszerbe összesen H_1+1 új paraméter kerül.

Mivel rendszerünkben a 4. táblázatban leírtak szerint legfeljebb 78 első hatványú leíró használunk, ha feltételezzük, hogy a hálózat rejtett rétegenként 78-nál több elemet tartalmaz, akkor fennáll a (61) egyenlőtlenség.

$$C_{M+p-1}^p H_1 = \frac{(M+p-1)!}{p!(M-1)!} H_1 > M + H_2 > H_1 + 1 > M + 1 \quad (61)$$


Ez alapján a lehető legegyszerűbb modellstruktúra megtartásához a modell komplexitását a második, majd az első rejtett rétegben, végül a bemeneti rétegben kell növelni.

Az is a hálózati struktúra növelése mellett szól, hogy a döntési fa és a neurális hálózat alapú regressziós modellek képesek működésük során nemlineáris jellemzők meghatározására és azok felhasználásával nemlineáris függvény közelítésére. Ezért a nemlineáris jellemzők meghatározását nem szükséges az előfeldolgozás során elvégezni és nem is javasolt, ha nincs bizonyosan elegendő szakértői ismeret, vagyis, ha nem ismert a modellezett folyamat elméleti modellje.

Bias – variancia egyensúly

A gépi tanulásban *bias* névvel hivatkozzák a regressziós modell (nem feltétlenül lineáris) konstans hatását, amely a tanítást megelőző, a feladattal és a rendszerrel kapcsolatos feltevésekből keletkezik. Túl magas bias esetén a rendszer nem képes a leíró és függő változók közötti összefüggések meghatározására. A *variancia* pedig a modellnek a tanító minták kis változásaira történő érzékenységet jelenti. Túl magas variancia esetén pl. a rendszer a véletlen zajjal terhelt kimeneti jeleket egyenként igyekszik megtanulni, ez csökkenti a tanító mintán mérhető hibát, azonban csökkenti az általános pontosságot is.


A magas variancia tehát azt jelenti, hogy a modell a tanító adatokat valószínűségi változótól mentes, hibátlan adatnak tekinti, túlságosan azokhoz ragaszkodik, ezért a jelenséget túlilleszkedésnek is nevezik. Ezt elkerülendő, mérni kell a modell általános teljesítményét. Ezt olyan adatokkal lehet megtenni, amelyek nem szerepeltek a modell kialakításához felhasználtak között, vagyis a rendszer számára még ismeretlenek. Ezért a rendelkezésre álló összes mintapárt tanító és tesztelő halmazra bontjuk, melyek közül általában a tanító nagyobb, 60%-40%-os osztástól egészen a 80%-20%-os arányig, a rendelkezésre álló mintaszám függvényében. A kísérletek során a tanító/tesztelő osztásba 70/30% arányban osztottam a mintákat, így a modellalkotáshoz az elvégzett szimulációk 70%-át, 3507 mintát használtam, a fennmaradó 30%-kal 1503 mintával, mint a rendszer számára ismeretlen adattal a modellek általános regressziós képességét vizsgáltam.




35. ábra: Példa minták funkcionális szétválasztása (zöld tanító-, kék tesztelő minták)

Az alább bemutatott példában 60 adatponttal mintavételezett zajos harmadfokú függvény látható. A regressziós modellek megalkotásához a rendelkezésre álló adatok 65%-át tanításra, 35%-át a rendszer tesztelésére különítettük el, egyenletes eloszlású, független véletlen kiválasztásokkal. A választás eredményét a 35. ábra szemlélteti.

A tanító mintákra egy legfeljebb 4 és egy legfeljebb 12 szint mély regressziós döntési fát illeszttem, majd a kapott modelleket felhasználtam a teljes mintatér becslésére. A modellek tanító mintákra illesztéseinek eredménye a 36.a és 37.a ábrán, míg a tesztmintákra történő illesztéseinek eredménye a 36.b és 37.b ábrán látható.




(a) 4 szint mély döntési fa alapú közelítés illeszkedése a tanító mintákra




(b) 4 szint mély döntési fa alapú közelítés illeszkedése a tesztelő mintákra

36. ábra: Zajos minta közelítésének illeszkedése

Látható, hogy a becslés jobban közelíti a tanító, mint a tesztelő mintákat és ez fokozódik a döntési fa mélységével. Ez a jelenség érthető, hiszen a modell a tanító minták alapján került kialakításra, a tesztelő minták a modell számára ismeretlenek, azok értékét a tanító mintákból igyekezett megbecsülni.



(a) 12 szint mély döntési fa alapú közelítés illeszkedése a tanító mintákra




(b) 12 szint mély döntési fa alapú közelítés illeszkedése a tesztelő mintákra

37. ábra: Zajos minta közelítésének illeszkedései 4 és 12 szint mély döntési fákkal


A tanító minták jobb közelítésével a véletlen mérési hiba átlagos közelítése romlik, a becslés eltávolodik a tesztelő mintáktól, ami az általános regressziós pontosság romlását jelenti. Ez látható a 37.a ábrán is. A regressziós döntési fa mélységének növelésével a tanítási pontosság nő, 8 szint mély döntési fa tanító mintát közelítő pontossága eléri a 100%-ot. Azonban a tesztadatokon mért általános pontosság a 4 szint mély fa esetében maximális, utána csökken. Vagyis az annál mélyebb fák esetében a modell varianciája túl magas. A 8 mély döntési fa fölött a modell már nem változik, ezért az általános pontosság is állandósul.

A túl magas variancia jelensége fokozottan látható a 37.b ábrán bemutatott polinomiális regresszióval történő becslés esetén, ahol a bemenetek komplexitását növeljük a 27. hatványig. Látható, hogy az általános regressziós képesség a 3. hatványnál maximális, utána csökken (nem meglepő, hiszen harmadfokú függvényt közelítettem).

A bias-variancia egyensúly tehát a rendszer azon konfigurációjánál van, amikor a tanító és tesztelő adatokon mért pontosság is maximális. Mivel ez a rendszer tanulási folyamaton kívüli paramétereinek (hiperparaméterek) függvénye, azok meghatározásával részletesen foglalkozni kell. Amennyiben a modell teljesítménye a fentiek alapján választott ponton nem elfogadható, a rendszer alkalmatlan a feladat elvárt szintű megoldására.



(a) Növekvő mélységű döntési fa alapú regresszió R^2 pontosságai
(X tengely: fa mélység; Y tengely: R^2 pont)



(b) Növekvő bemeneti komplexitású polinomiális regresszió
(X tengely: legmagasabb hatvány; Y tengely: R^2 pont)

37. ábra: a példa függvény tanító és tesztelő mintájának közelítési hibái és azok különbsége

Rendszerparaméterek meghatározása

A gépi tanuló modell paraméterei két fő csoportra bonthatók. Rendszerparamétereknek, vagy hiperparamétereknek (hyperparameters) nevezik azokat a paramétereket, amelyeket a modell létrehozásakor, a tanítási folyamat előtt, attól függetlenül kell meghatározni és beállítani. Az ilyen paraméterek általában a modell tanítása és működése során nem változnak. A paraméterek másik fő csoportja a tanulási folyamat által módosított paramétereket foglalja magába, melyeket a rendszer dinamikus paramétereinek, vagy egyszerűen a rendszer paramétereinek nevezik.

Rendszerparaméterek:

- lineáris regresszió esetén
 - o a nemlinearitást biztosító bemeneti komplexitás növelés, a bemeneti változók hatványkombinációjának szükséges legmagasabb foka

- döntési fa alapú regresszió esetén
 - o a döntési fa maximális mélysége
 - o variancia metrikák
- neurális hálózat esetén
 - o rejtett rétegek száma
 - o rejtett rétegek mérete
 - o aktivációs függvények

Dinamikus paraméterek:

- lineáris regresszió esetén
 - o a bemeneti változók lineáris kapcsolatában felhasznált együtthatók
- döntési fa alapú regresszió esetén
 - o az egyes döntéshez választott bemeneti változók
 - o az egyes döntésekhez használt bemeneti változó küszöbök
 - o az egyes kimeneti értékek
- neurális hálózat esetén
 - o a feldolgozó egységek közötti súlyok

A rendszer tanulási folyamaton kívüli paramétereinek meghatározására a gépi tanulásban általában rendszervalidáció használt. Ez azt jelenti, hogy a rendelkezésre álló bemeneti-kimeneti mintapárokat a korábbi kettő helyett három részre bontják. 60%-ot a rendszer kialakítására, 20%-ot a legjobb rendszerparaméter beállítás kiválasztására, a maradék 20%-ot pedig az általános teljesítmény mérésére használják. Az egyes minták a korábbiakhoz hasonlóan egyenletes eloszlású véletlen döntés alapján kerülnek besorolásra. Jelen kutatásban is ezt az eljárást alkalmaztam. Az egyes rendszerparaméter beállításokat grid-search módszerrel készítettem, ami az egyes paraméter dimenziók lehetséges értékeinek összes permutációját előállította. A vizsgálandó rendszerparaméter-csoportok számának csökkentése érdekében az egyes dimenziók mentén korábbi tapasztalok alapján kijelölt intervallumokat kis felbontással vizsgáltam, majd a potenciálisan jó megoldást hordozó területeken a felbontást növeltem.

Eredmények

A továbbiakban a közelítő eljárások abszolút és relatív hibáját, illetve azok szórását, valamint azok R^2 pontját hasonlítom össze. Az összehasonlítás alapján kizárhattam olyan eljárásokat, amelyek pontossága vagy megbízhatósága nem megfelelő. Ezután a kiválasztási és modell alkotási folyamat a megmaradt lehetőségek flexibilitási, használhatósági vizsgálatával folytatódhat.

Pontosság

A vizsgálatok során először a közelítő eljárások pontosságát mértem és hasonlítottam össze az R^2 pont 10 független mérésen számított átlagával.

6. táblázat: Regressziós eljárások R^2 pontjai az alkalmazott bemenetek függvényében

Modell	indirekt A/S			Egyszerű indirekt leírók (14)		
	1. hatv.	2. hatv.	3. hatv.	1. hatv.	2. hatv.	3. hatv.
DT _{MAE-9}	0,97	0,97	0,97	0,97	0,96	0,96
DT _{MSE-9}	0,97	0,97	0,97	0,97	0,97	0,97
LR	0,70	0,93	0,96	0,75	0,96	0,99
LR _{LASSO}	0,71	0,93	0,95	0,74	0,96	0,99
LR _{Ridge}	0,72	0,93	0,95	0,74	0,96	0,99
NN	0,95	0,95	0,90	0,99	0,99	0,98
Modell	blokk koordináták (18)			funkcionális pontfelhő (75)		
	1. hatv.	2. hatv.	3. hatv.	1. hatv.	2. hatv.	3. hatv.
DT _{MAE-9}	0,89	0,90	0,90	0,89	0,92	0,92
DT _{MSE-9}	0,90	0,90	0,90	0,90	0,92	0,92
LR	0,68	0,94	0,99	0,67	0,96	0,99
LR _{LASSO}	0,67	0,94	0,98	0,68	0,96	0,99
LR _{Ridge}	0,68	0,94	0,99	0,64	0,96	0,73
NN	0,97	0,98	0,91	0,99	0,99	0,94


Az R^2 pont jó összehasonlítási alap, kifejezi a leíró és függő változók korrelációjának kapcsolatát, de nem elégséges annak eldöntésére, hogy az eredmények elég pontosak-e ahhoz, hogy az építész szakértők a közelített eredményeket és az azokból megfogalmazott következtetéseket elfogadják. Ezért a 7. táblázatban és a 38. ábrán látható az egyes eljárások abszolút hibája és annak szórása.

7. táblázat: Regressziós eljárások átlagos abszolút hibája és szórása az alkalmazott bemenetek függvényében

Modell	A/S			Egyszerű indirekt leírók (14)			blokk koordináták (18)		
	1. hatvány	2. hatvány	3. hatvány	1. hatvány	2. hatvány	3. hatvány	1. hatvány	2. hatvány	3. hatvány
DT _{MAE-9}	7	10	11	23	14	17	1	16	20

	305	314	313	298	327	327	594	557	521
DT _{MSE-9}	13	19	8	16	27	16	32	29	33
	301	302	305	278	196	291	548	525	496
LR	8	15	21	27	10	14	167	13	9
	873	438	361	843	333	183	949	406	148
LR _{LASSO}	15	17	5	6	16	14	49	6	18
	864	483	367	835	333	205	938	414	253
LR _{Ridge}	41	10	8	32	15	15	21	15	15
	996	451	362	850	332	185	971	477	241
LR _{Ridge}	41	10	8	32	15	15	21	15	15
	996	451	362	850	332	185	971	477	241
NN	289	279	464	120	132	229	186	132	381
	243	238	337	125	133	539	168	129	311

Ahogy a 38. ábráról leolvasható, az abszolút hiba átlaga az éves energiaigényhez viszonyítva alacsony, szinte elhanyagolható. Azonban a hiba szórása csak az első 3 modell esetében marad 500kWh/év alatt.




38. ábra: Az A/S épület geometria leíró modellek abszolút közelítési hiba átlaga és szórása [kWh/év]

Az átlagos abszolút hiba megmutatja, hogy a legjobb esetben majdnem 200kWh/év, legrosszabb esetben majdnem 1MWh/év a hiba. Ez a közel ötszörös eltérés abszolút volta miatt még mindig nem írja le megfelelően a becslési pontosságot. Ez alapján nem hozható döntés a módszer építészeti alkalmazásának elfogadásáról. Az elfogadási döntés támogatására a döntés várható hibájának más megfogalmazása is szükséges. Az abszolút százalékos hiba (MAPE) a közelített értékkel arányosítja a hibát.

8. táblázat: Regressziós eljárások átlagos abszolút százalékos hibája és szórása az alkalmazott bemenetek függvényében


Modell	A/S			Egyszerű indirekt leírók (14)			blokk koordináták (18)		
	1. hatvány	2. hatvány	3. hatvány	1. hatvány	2. hatvány	3. hatvány	1. hatvány	2. hatvány	3. hatvány
DT _{MAE-9}	0	0	0	0	0	0	0	0	0
	0,03	0,03	0,03	0,03	0,03	0,03	0,06	0,05	0,05
DT _{MSE-9}	0	0	0	0	0	0	0	0	0
	0,03	0,03	0,03	0,03	0,03	0,03	0,05	0,05	0,05
LR	0	0	0	0	0	0	0	0	0
	0,08	0,04	0,03	0,08	0,03	0,02	0,09	0,04	0,01
LR _{LASSO}	0,01	0	0	0,01	0	0	0	0	0
	0,08	0,04	0,03	0,08	0,03	0,02	0,09	0,04	0,02
LR _{Ridge}	0,01	0	0	0	0	0	0	0	0
	0,1	0,04	0,03	0,08	0,03	0,02	0,09	0,04	0,02
NN	0,027	0,026	0,041	0,011	0,012	0,021	0,017	0,012	0,035
	0,02	0,02	0,03	0,011	0,011	0,017	0,015	0,012	0,04

Ugyanez a tendencia figyelhető meg a relatív hiba átlagot és szórást bemutató 39. ábrán is. A becsült értékhez viszonyított relatív hiba minden modell esetében 2% alatt maradt, azonban 4% körüli relatív szórást csak a megfelelően paraméterezett lineáris regresszió és a neurális hálózat produkálta.



39. ábra: Az A/S épület geometria leírók használó modellek relatív közelítési hiba átlaga és szórása [%] a szórás növekvő sorrendjében

Az R^2 pontok 40. ábrán bemutatott összehasonlítása alapján is az jelenthető ki, hogy a leíró változók harmadik és második kitevőjű hatványait tartalmazó lineáris regresszió és az elsőfokú leíró változókat feldolgozó előrecsatolt neurális hálózat közel azonos, 0.95 körüli teljesítménye megfelelő, míg a többi modell teljesítménye 0.75 pont alatt marad, azok az épület-energetikai regressziós feladat megoldására nem alkalmazandók.



40. ábra: Közelítő eljárások R² pontja

A fentiek alapján a további vizsgálatokhoz megfelelő teljesítményű modellek

- lineáris regresszió a bemenő változók legfeljebb harmadfokú szorzatkombinációival
- neurális hálózat változtatás nélküli bemenő változókkal


melyek közül a regressziós neurális hálózatot választottam, az alábbi okok miatt:

- a modell megalkotása és használata nem igényli a bemenő adatok előfeldolgozását
- a modell strukturális kialakításában rejlő lehetőségek jobban illeszkednek a megfogalmazott kutatási tervekhez

Hálózati struktúra választása


Ahogy a 6. táblázatban látható, R²=0.99 pontosság érhető el. Jelen fejezet célja az energetikai és komfort regressziós feladatok megoldására leginkább alkalmas, minimális komplexitású hálózati struktúra megtalálása úgy, hogy a korábban elért pontosság ne csökkenjen. Az ehhez szükséges rendszer hiperparamétereinek keresését grid-search algoritmussal végeztem. A fő kérdéseket a hálózat rejtett rétegeinek száma, illetve azok mérete jelentette.

Először az egy, majd a két rejtett rétegű hálózat teljesítményét vizsgáltam a rétegekben található neuronok száma szerint. A 41. ábra az egy rejtett réteget tartalmazó hálózat teljesítményének alakulását mutatja a rejtett réteg neuronszámának változásával. Az ábrán látható, hogy a teljesítményplató 450 feldolgozó egység körül alakult ki. Az elért teljesítmény pedig némileg a korábbi R²=0.99 felett volt, de nem haladta meg az R²=0.992 pontot.



41. ábra: Egyrétegű neurális hálózat fűtési energiaigény becslésének R² pontja

A második vizsgálati eset olyan hálózatokra terjedt ki, melyek kettő rejtett réteget tartalmaztak, rétegenként megegyező számú neuronnal. Ez a mérés segített meghatározni, hogy a következő mérésben melyik szegmensben kell az elemszám felbontását növelni. A 42. ábrán látható, hogy az előírt R²=0,99 pontosságot rejtett rétegenként 150 neuronnal eléri a hálózat. Mivel a teljesítmény az R²=0,994 pontot is majdnem elérte, további strukturális optimalizálás volt szükséges.




42. ábra: Két azonos méretű rejtett réteget tartalmazó hálózat fűtési energiaigény becslésének R² pontja

Ha a rendszer komplexitását a felhasznált paraméterek számában fejezem ki, akkor összehasonlíthatom a 78 (75+3) bemenetet és 1 kimenetet alkalmazó hálózatok súlyainak számát:

$$78 \cdot 450 + 450 = 79 \cdot 450 = 237 \cdot 150 > 78 \cdot 150 + 150 \cdot 150 + 150 = 229 \cdot 150$$

Ez alapján kijelenthettem, hogy az egy rejtett rétegben 450 neuront és a két rejtett rétegben 150-150 neuront tartalmazó hálózat komplexitása közel azonos, azonban a kétrétegű hálózat feature extrakciós képessége jobb, ezért azt részesítettem előnyben.


A 43. ábrán két függetlenül méretezett rejtett réteget tartalmazó neurális hálózatokkal végeztem méréseket. Az első rejtett réteg 50-200, a második rejtett réteg 0-200 feldolgozó egységet tartalmazott.



43. ábra: Legfeljebb két eltérő méretű rejtett réteget használó neurális hálózat fűtési energiaigényének R^2 pontossága


Az ábra jobb oldalán látható sötét rész a tulajdonképpen egyrétegű hálózat teljesítménye, hiszen a második réteg nem tartalmazott feldolgozó elemet. Ez a teljesítmény jelentősen elmarad az optimálistól, viszont nehezíti a plató érthető megjelenítését. A közel azonos teljesítményű hálózatok közötti különbség hangsúlyozására a 44. ábrán a pontosan kettő rejtett rétegrétegű hálózatok teljesítményeit jelenítettem meg.

Mivel a 44. ábra felülete az egyenletlenségek térbeli elrendeződése miatt nehezen értelmezhető, az adatokat 45. ábrán más diagramtípussal is bemutatom.



44. ábra: Pontosán két rejtett réteget tartalmazó neurális hálózat fűtési energiaigényének R^2 pontjait bemutató felületdiagram


A 45. ábra jelmagyarázata alapján, ahol a vörös értékek az alacsonyabb, a zöld értékek a magasabb R^2 ponttal mért teljesítményt jelölik, a kép jobb felső negyedében látható, hogy a rétegenként 125 vagy több neuront használó hálózatok pontossága már $R^2=0.99$ pont körüli.



45. ábra: Pontosán két rejtett réteget tartalmazó neurális hálózat fűtési energiaigényének R^2 pontjait ábrázoló színtérkép

Azonban a pontosság nem monoton változó. Ennek a variabilitásnak az oka a modell kialakító, tanító eljárás hiperparaméterei és sztochasztikus jellege lehet, ezért a modell


rendszerparamétereit mellett a tanító eljárás rendszerparamétereinek megválasztására is hangsúlyt kell fektetni. A **Rendszerparaméterek meghatározása** fejezetben leírtak alapján az ilyen jellegű paramétereket a permutációkat előállító grid-search algoritmussal és rendszer validációval választottuk. Ezt a validációt a tanító folyamat megfelelő paramétereinek vizsgálatára is el kell végezni.



46. ábra: Egy (450 neuron) és két (150, 150 neuron) rejtett réteget tartalmazó neurális hálózat validációs R^2 pontossága a tanító ciklusok száma szerint

A tanító eljárás során a modellparamétereket a csökkenő gradiens módszerével módosítom, így a modell minden tanító lépésben közelebb kerül a lokális vagy globális optimumhoz. Amennyiben a konvergencia fennáll, a tanítást folytatni kell, azonban az optimum közelítésének megállása, esetleg távolodás esetén a további tanítás felesleges. Ezért a tanító lépések, más néven tanító *epoch*-ok számának meghatározása a tanítási folyamat lényeges kérdése. Mivel e paraméter meghatározása, módosítása nem része a tanítási folyamatnak, ez a tanító eljárás rendszerparaméterének tekintendő és validációval keresendő. A 46. ábrán egy és két rejtett réteget tartalmazó neurális hálózat regressziós pontossága látható, a tanítási folyamat hosszának, a végrehajtott tanítási ciklusoknak, epoch-oknak függvényében. Az ábra alapján kiválasztható, hogy az a ciklusszám, amit végrehajtva mindkét hálózattípus maximális közeli teljesítményt nyújt, kb. 2000 epoch.


A 45. ábra elkészítéséhez 1200 epoch-ot használtam, amivel a tanított modellek nem érték el teljesítményük maximumát. A pontosabb eredmény meghatározása érdekében legalább 2000 tanítási ciklus alkalmazása javasolt. A megismételt mérés eredményét a 47. ábra mutatja, amin már jól kirajzolódik a komplexebb hálózatok jobb teljesítménye.



47. ábra: 2000 tanítási ciklussal tanított, pontosan két rejtett réteget tartalmazó neurális hálózat fűtési energiaigényének R^2 pontjait ábrázoló szintérvkép

A modell komplexitástól függő teljesítmény növekedés még mindig nem monoton növekvő, ennek okait a **Stabilitás** fejezetben részletesen vizsgálom. Az azonban jól leolvasható, hogy mindkét rejtett rétegben 150 feldolgozó elemet tartalmazó neurális hálózat megfelelően jól teljesített, hiszen pontossága meghaladta az előírt $R^2=0.99$ minimumot.

Az általam javasolt teljesen előrecsatolt (dense) neurális hálózat direkt épületkonfiguráció reprezentációs bemenet és fent bemutatott tanítási eljárás alkalmazásával az éves energiaigényeket és komfortszinteket a 48. ábrán látható R^2 ponttal és MAPE %-kal mért pontossággal közelítette.



48. ábra: A szimulációs adatok közelítésének pontossága R^2 ponttal és MAPE%-kal mérve

A 48. ábráról leolvasható, hogy a modell minden szimulált adatsor közelítésében jól teljesített. A fűtési-, világítási energiaigény, a természetes világítási komfort, valamint a teljes energiaigény közelítése esetén a pontosság átlagosan 1% alatt maradt, míg legrosszabbul a hűtési energiát tudta közelíteni, abban az esetben a pontosság 4.5% alatt maradt.


Konfiguráció leíró választás

A 6. táblázatból az olvasható ki, hogy a regressziós feladat ellátására közel azonos teljesítménnyel alkalmazható indirekt és direkt leírót alkalmazó neurális hálózat alapú modell. Fontos tehát, hogy megvizsgáljuk melyik leíró szolgáltatja a lehető legjobb eredményt.

9. táblázat: Neurális hálózat R^2 pontjai a bemenetek függvényében

A/S	14 egyszerű leíró	Blokk koordináták	Pontfelhő
0,938	0,988	0,958	0,99
0,935	0,98	0,961	0,99
0,956	0,985	0,968	0,989
0,936	0,989	0,968	0,992
0,94	0,986	0,981	0,992
0,941	0,983	0,962	0,992
0,951	0,986	0,981	0,991
0,944	0,987	0,964	0,978
0,945	0,99	0,967	0,991
0,949	0,984	0,974	0,995

A neurális hálózattal végzett 10 mérés eredménye a 9. táblázatban olvasható, box diagramja pedig a 41. ábrán látható.



49. ábra: Neurális hálózat regressziós hatékonysága a bemenetek függvényében [R^2]

A táblázat legjobb oszlopa (diszkrét funkcionális pontfelhő) elemeinek rendezése után a medián érték 0,991, az alsó fél lista középső értéke, az alsó kvartilis (Q_1) 0.990, míg a felső fél lista középső értéke, a felső kvartilis (Q_3) 0.992. A felső és az alsó fél kvartilis különbsége, vagyis az interkvartilis távolság (Q_3-Q_1) 0,002.

A 49. ábráról leolvasható, hogy a funkcionális pontfelhőt alkalmazó neurális hálózat alkalmazása során előfordult egy, a többihez képest nagyon rosszul teljesítő modell, azonban az ilyen esetek száma 10%. Vagyis ismételt modellalkotással az ilyen szélsőséges pontok elkerülhetők. A pontos ismétlésszámmal a **Stabilitás** fejezetben foglalkozom. A funkcionális pontfelhő alkalmazásakor egy modellt a megbízhatósági területen kívül esőnek kell tekintenünk. Máshogy fogalmazva az esetek 90%-ában a modell teljesítménye a megbízhatósági zónába kerül. Ez tulajdonképpen az előállítandó modellek számának növelésével és validációjával áthidalható. A fentiek fényében kijelentem, hogy ez a konfiguráció leíró a leghatékonyabb. Hatékonysága mellett azért is ezt a leírót javasoltam, mert ez hordozza magában a legdinamikusabb változtatási lehetőséget, hiszen a hasonló méretű keresési térben az a konfigurációt felépítő blokkok funkciójának bővítése mindössze a pontfelhő értékészletének növelését eredményezi, a modell szerkezetében nem feltétlenül okoz változást.

Stabilitás

Belátható, hogy egy függvény egy minimum helye a csökkenő gradiens elvet használva meghatározható. Az is belátható, hogy ha ez a függvény (pozitív állású) parabola alakú, akkor a minimum helye a függvény bármely kiindulási helyéről elérhető. Amennyiben a függvény konkáv, több minimum hellyel és értékkel is rendelkezik, a csökkenő gradiens módszer segítségével ekkor is elérhető egy minimum, azonban a minimum globalitása nem biztosított. Továbbá, a nem globális minimumok számának növekedésével a globális minimum meghatározásának esélye csökken. Mivel a tanító eljárásnak nincs információja sem a minimalizálandó függvény alakjáról, sem a minimumok számáról vagy helyéről, a legjobb kiindulási hely az értelmezési tartományból egyenletes eloszlású véletlendöntéssel választott több kiindulási hely és több, azokból kialakított modell. Ez a véletlen inicializáció a csökkenő gradiens módszerének kezdeti állapottal szemben támasztott igényeit is kielégíti. Az eredmények varianciáját nem csak a véletlen inicializáció adja. A **Bias-variancia egyensúly** fejezetben bemutattam, hogy a modell kialakításához véletlen döntéssel választott leíró (bemeneti) és függő (kimeneti) változó párokat használtam. Belátható, hogy a mintapárok

választása hatással van a kialakított modellre, annak teljesítményére. A továbbiakban a két valószínűségi hatást külön vizsgálom.

Mivel az épületkonfiguráció leíró felhasználása nélkül működő regressziós modell a legjobb megoldástól távol van, a további vizsgálatokban nem szerepel.


A 9. táblázat és a 49. ábra alapján a diszkrét funkcionális pontfelhőt alkalmazó neurális hálózat megbízhatósági intervalluma kb. a medián körüli 4·IQR, vagyis $R^2=0,991$ körüli $\pm 0,004$ tartomány, ami az előírt $R^2=0,99$ érték fölött van.

9. táblázat: véletlen kezdőállapotból, véletlen mintákkal tanított hálózat pontossági statisztikái. Az összehasonlításban alkalmazott hálózatok épület konfiguráció leírói bemenő változói a jobb indirekt (14 egyszerű leíró halmaza) és a jobb direkt (diszkrét funkcionális pontfelhő) leírók

R^2	Max	Mean	Std. dev.	Min
Indirect	0,988	0,9865	0,00187	0,984
Direct	0,992	0,991	0,00148	0,987

A szórás alapján számított megbízhatósági tartomány $R^2=0,00148 \cdot 3=0,00444$.

Az 50. ábrán megjelenített interkvartilis távolságokat vizsgálva látható, hogy a direkt leíró használó modell IQR által meghatározott szóródása alacsonyabb és biztonsági tartománya is szűkebb. Az ábráról leolvasható $IQR=0,1\%$ szintén $0,4\%$ -os megbízhatósági tartományt mutat.



50. ábra: A jobb direkt és indirekt konfiguráció leíró használó modellek varianciája véletlen inicializáció és véletlen tanító mintagyűjtemény választás esetén

A véletlen mintaválasztás hatása


Ebben a kísérletben a neurális hálózat modell szintén véletlen inicializációval készül, mert ez a tanítási folyamat alapkövetelménye, azonban ezt az inicializációt csak egyszer végeztem el, a hálózat tanítása a kísérlet 10 futtatása alkalmával ugyanabból az állapotból indul. Az egyenletes

eloszlású véletlen döntés alapú tanító/tesztelő mintaválasztás minden esetben újra megtörténik, így a modell minden esetben más tanító mintagyűjtemény alapján készül. A módosítástól azt várom, hogy a szóródás oka a véletlen mintaválasztás hatására korlátozódik. A 10. táblázat mutatja az így készült legjobb indirekt és legjobb direkt konfiguráció leírót alkalmazó 10-10 modell teljesítményének statisztikáit.

10. táblázat: azonos kezdőállapottól, véletlen mintahalmazzal tanított hálózat pontossági statisztikái

R ²	Max	Mean	Std. dev.	Min
Indirect	0,988	0,9864	0,00112	0,982
Direct	0,994	0,993	0,00083	0,992

A csökkenő, de még jelenlevő szóródás a véletlen mintaválasztás hatása lehet. Az 51. ábra doboz diagramjáról a kisebb szóródást mutató direkt reprezentációt használó esetben 0.1%, míg a nagyobb szóródást mutató indirekt reprezentáció esetén is legfeljebb 0.2%-os IQR olvasható le, ami direkt esetben 0.4%, indirekt esetben pedig 0.8%-os megbízhatósági tartományt mutat.



51. ábra: A jobb direkt és indirekt konfiguráció leírót használó modellek variációjának véletlen tanító mintagyűjtemény választás esetén


A modell véletlen inicializációjának hatása

A következő kísérletben az előzővel ellentétben a véletlen alapú tanító/tesztelő mintaválasztást végeztem el egyszer és ugyanazt a tanító mintahalmazt használtam 10 független véletlen inicializációval készített hálózat tanítására. A 11. táblázat tartalmazza az így készült hálózatok pontossági statisztikáit. A kísérlet során azt várom, hogy az eredmények szóródásának oka a véletlen kezdőállapokra korlátozódik.

11. táblázat: véletlen kezdőállapotból, azonos mintahalmazzal tanított hálózat pontossága


R ²	Max	Mean	Std. dev.	Min
Indirect	0,990	0,987	0,00169	0,984
Direct	0,993	0,992	0,00108	0,990

A szórásokat ábrázoló 11. táblázat alapján az indirekt modell szórás alapú megbízhatósági tartománya $R^2=0.005$, míg a direktté $R^2=0,003$. Az IQR alapú becslési statisztikákat bemutató 52. ábra alapján az indirekt modell MAPE megbízhatósági tartománya 1.2%, míg az indirekt modell esetében ez 0.8%.



52. ábra: A jobb direkt és indirekt konfiguráció leíró használó modellek MAPE varianciája véletlen inicializáció esetén

A 53. ábráról leolvasható, hogy az eredmények szórással vizsgált szóródása mindkét esetben csökkent. A csökkenések karakterisztikája az épület konfiguráció leírótól függetlenül hasonló. Az is leolvasható, hogy a véletlen mintaválasztás által okozott szóródás alacsonyabb, mint a véletlen inicializáció által okozott.



53. ábra: R² pont szórásának alakulása a modellalkotási folyamat véletlen komponensei alapján

A szórás és az IQR alapú R² és MAPE statisztikai vizsgálatok eredményei azt mutatták, hogy a véletlen modell inicializálás és véletlen tanító mintahalmaz választás csökkenti a leíró és a

függő változók varianciájának összefüggését, de a MAPE szóródására nincs számottevő hatása. Ezek alapján a véletlen inicializációval és véletlen tanító mintahalmaz választással történő modell előállítás ismételt végrehajtása esetén a tanító és validációs pontosságok átlagai közül a legmagasabbal rendelkező modellt választva az építész szakértők által előírt pontossági tartomány betartható.

Érzékenységvizsgálat

A kutatás egyik fő célja az épületforma energetikai és komfort optimalizációs jelentőségének kimutatása és a felfedezett összefüggések építészeti tématerületre történő visszavezetése, az épületformát, mint tervezési változót közvetlenül használok, akkor is, ha az analitikus dimenziócsökkentő eljárások (pl. Főkomponens Analízis – Principal Component Analysis – PCA [100]) előfeldolgozásként történő alkalmazása a bemenő változók számának csökkentésével lényegesen egyszerűbb regressziós modelleket eredményezne. A PCA alkalmazásával a 14 egyszerű indirekt leíróval reprezentált mintákat az adatok varianciájának 97%-át megtartva egy 5 dimenziós térbe tudtam transzformálni, amivel az egy rejtett, abban 25 neuront tartalmazó hálózat is képes volt 0,97 R^2 pontos közelítést elérni. Azonban a PCA eredményeként előálló 5 dimenzió az építész szakértők által nem értelmezhető, így számukra az azokkal kapcsolatos következtetések sem hasznosak.

A [101] tanulmányban szimulációs adatok felhasználásával végeztek érzékenységvizsgálatot, melynek során azokat a tervezési változókat igyekeztek kiválasztani, amelyekre a fenntartható épületek létrehozásához szükséges optimalizációs folyamatokban leginkább fókuszálni kell. A szerzők megállapítása szerint az érzékenységvizsgálatot a tervezésnek olyan korai fázisában kell végrehajtani, amikor a lényeges tervezési változók még befolyásolhatók. A tanulmány egy dániai irodaház tervezése során Morris módszerrel elemezte különböző funkciójú felületek méreteit és egyéb fizikai jellemzőket. A vizsgálatokhoz 88 szimulációt kellett elvégezni, melyek alapvetően egyféle épületkonfigurációt tartalmaztak.

Mivel a dolgozatom fókuszában az épületkonfiguráció energiaigényre és komfortszintre gyakorolt közvetlen és közvetett hatásának vizsgálata volt, hasonló megközelítést alkalmazó, de az épületkonfigurációt, mint tervezési változót felhasználó új megoldásra volt szükség.

A **Paraméterezett szimulációk** fejezetben a szimulációs adatok értékeléséből következtettem a konfiguráció energetikai és komfort teljesítményre gyakorolt hatására. Ott beláttam, hogy a konfiguráció lényeges tervezési szempont. A továbbiakban azt vizsgáljuk, hogy a rendelkezésre

álló leíró változók közül abszolút és egymáshoz viszonyítva melyiknek milyen mértékű az energetikai és komfort teljesítményre gyakorolt hatása.

A leíró változók egymáshoz viszonyított hatását korábbi tanulmányban vizsgáltam [102]. Ehhez a bemenő változók helyes megválasztása kritikus, mert az alkalmazott Morris módszer azok egyenletes eloszlását igényli a [0, 1] intervallumon. Azonban a gyakorlatban ez ritkán fordul elő. Az értékkészlet transzformálható lenne, de a valószínűségi változók eloszlása nem ismert. A probléma kiküszöbölésére speciális mintavételezési eljárásokat használtam, melyek közül néhány a Latin hiperkocka technikán, mások pedig a megfelelő távolságmetrika megválasztásán alapulnak. A lényegük, hogy a speciális mintavételezéssel előállított mintákon a Morris módszer trajektóriáinak szintjei egységnyi távolságra helyezkednek el.

A vizsgálatok eredményeként, melyekben az összes korábban bemutatott leíró változó szerepelt, azt állapítottam meg, hogy a geometriai konfiguráció nem a legfontosabb, de az energiaigény meghatározásának lényeges komponense.

Döntési fa számára lényeges tulajdonságok


A döntési fa egy bináris fagraf, melynek minden belső pontja egy döntés, amely során egy meghatározott bemeneti változó értékével kapcsolatos egyszerű döntés születik. A döntési fa megalkotása az egyes döntések során vizsgált bemenő változók kiválasztását és a vizsgálati küszöbök meghatározását jelenti. Az egyes változók felhasználásának gyakorisága és az összesített variancia csökkenés alapján meghatározható az egyes változók általános döntési jelentősége.

12. táblázat: Döntési fák becslési pontosságai és a felhasznált leíró változók fontossági súlyai

R ²	Output	A/S	Struct	WWR	Ori
0,968	HE	0,240	0,524	0,028	0,208
0,889	CE	0,093	0,189	0,646	0,072
0,963	LE	0,043	0,000	0,935	0,022
0,921	TC	0,089	0,009	0,840	0,062
0,963	DF	0,034	0,001	0,899	0,066
0,952	SE	0,149	0,592	0,050	0,209

A (40) képletben bemutatott MSE alapú variancia nyereséget felhasználó döntési fa alapú regressziós modell esetében az egyes bemeneti változóknak a döntési fa kimenetében várható közreműködésének valószínűsége alapján az egyes bemenetek fontosságát a 12. táblázat tartalmazza. A táblázatból kiolvasható, hogy a *fűtési- és az összes energia esetében a*

leglényegesebb a szigetelés (0.5), míg a **többi esetben a leglényegesebb az ablakozás aránya** (0.6-0.9). A bemeneti változók hatásának relatív különbségét az 50. ábra szemlélteti.



50. ábra: A bemenő változók hatásának összehasonlítása a becült adattípusok függvényében

Az ábráról leolvasható, hogy a fűtési-, hűtési- és az összes energia esetében az épületkonfiguráció hatása az orientációválasztással azonos fontosságú. A világításhoz, szoláris energiához kapcsolódó kimenetek meghatározásában legjelentősebb, szinte egyedül lényeges bemenet az ablakozási arány.

A polinomiális regresszió normalizált abszolút súlyai

A polinomiális regresszió a függő kimenetet a leíró változók lineáris kombinációjaként állítja elő. A modell megalkotása a leíró változók lineáris kombinációs együtthatójának keresését jelenti. A vizsgálatok során nemlineáris függvények közelítési pontosságának javítása érdekében a bemeneteket a leíró változók különböző hatványú szorzatkombinációival bővítettem.

A 13. táblázatból kiolvasható, hogy az alapértelmezett 4 db leíró alkalmazása esetén a leghangsúlyosabb bemenet a konfiguráció leíró A/S volt (0.8-0.9), azonban az ilyen modell alkalmazása esetén a közelítési pontosság nem volt megfelelő $R^2=0.7-0.8$.

13. táblázat: Lineáris regressziós modellek bemenő változóinak abszolút súlyai és a becslési pontosság

R ²	Output	A/S	Struct	WWR	Ori
0,721	HE	0,906	0,423	0,000	0,000
0,771	CE	0,832	0,555	0,022	0,001
0,833	LE	0,990	0,099	0,104	0,003
0,831	TC	1,000	0,015	0,026	0,001
0,842	DF	0,989	0,132	0,068	0,002
0,691	SE	0,847	0,531	0,001	0,000


A 14. táblázatban látható, hogy a legfeljebb másodfokú bemenet szorzatkombinációkat használó polinomiális regresszió esetén a kimenetekre gyakorolt legnagyobb hatása az egy, komplex épület konfiguráció leírónak volt (0.85-0.99 között, a becsült kimenettől függően).

14. táblázat: Legfeljebb másodfokú bemenetet használó polinomiális regressziós modellek bemeneteinek normalizált abszolút súlyai és becslési pontossága

R ²	Out	A/S	Struct	WWR	Ori
0,93	HE	0,99	0,05	0,01	0,01
0,86	CE	0,98	0,02	0,01	0,00
0,92	LE	0,85	0,02	0,32	0,03
0,89	TC	0,98	0,01	0,01	0,00
0,91	DF	0,98	0,00	0,01	0,01
0,92	SE	0,99	0,04	0,00	0,01

R ²	Out	A/S ²	A/S * Struct	A/S * WWR	A/S * Ori	Struc ²	Struct * WWR	Struct * Ori	WWR ²	WWR * Ori	Ori ²
0,93	HE	0,00	0,03	0,00	0,00	0,14	0,00	0,00	0,00	0,00	0,00
0,86	CE	0,20	0,06	0,00	0,00	0,05	0,00	0,00	0,00	0,00	0,00
0,92	LE	0,42	0,08	0,04	0,00	0,05	0,00	0,00	0,00	0,00	0,00
0,89	TC	0,20	0,01	0,00	0,00	0,02	0,00	0,00	0,00	0,00	0,00
0,91	DF	0,21	0,02	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00
0,92	SE	0,06	0,02	0,00	0,00	0,12	0,00	0,00	0,00	0,00	0,00

Az 51. ábra szemlélteti az egyes bemeneti változók hatásainak arányát. Mind a hat esetben leglényegesebb összetevő az épület konfiguráció komplex leírója volt.



51. ábra: Legfeljebb másodfokú bemenetet használó polinomiális regressziós modellek bemeneteinek normalizált abszolút súlyai

A legfeljebb harmadfokú bemenetek esetében a szorzatkombinációval előállított leíró változók száma a 34-re növekedett, így azok táblázatos vagy grafikus megjelenítése nehézkes. Azonban a lineáris regressziós modellben legkisebb négyzetek módszerével előállított együtthatók a normalizált abszolút értékeinek vizsgálatával kiderül, hogy a modellel végzett közelítés során legnagyobb hatása az épületkonfiguráció és a szigetelés szorzatának van ($A/S*Struct$: 0,802), második legnagyobb hatású az épületkonfiguráció (A/S : 0.534) , harmadik pedig az épületkonfiguráció és a szigetelés négyzetének szorzata ($A/S*Struct^2$: 0.267), a többi bemenő változó hatása szinte elhanyagolhatóan kicsi volt.

Tézisek

Kutatásom célja a ED módszer bővítéseként bemutatott Energia Design Szintézis (Energy Design Synthesis - EDS) eljárás első két lépésének, a megvalósítható épületek kiválasztásának és a komplex szimulációk elvégzésének támogatása gépi tanuló algoritmusok alkalmazásával.

A probléma alkalmazott informatikai központú megoldása érdekében az alábbi téziseket fogalmaztam meg.

Saját eredményeim, tézisek:

I. Tézis

Azonos energia és komfort teljesítménnyel rendelkező épületkonfigurációk kizárásával csökkentettem a szimulációval és regresszióval vizsgálandó esetek számát.

- a. Kimondtam és bizonyítottam a következő tételt: az alkalmazott keresési térben egy konfigurációval építészetiileg egybevágó összes konfiguráció előállítható legfeljebb két lépéses transzformációsorozatokkal.
- b. Felhasználva, hogy az építészetiileg egybevágó épületek azonos energetikai és komfort teljesítménnyel rendelkeznek, megfogalmaztam a tétel következményét: 12 darab, legfeljebb 2 lépés hosszú transzformációs szekvenciával a vizsgálandó konfigurációk halmaza az építészetiileg egybevágók kizárásával jelentősen csökkenthető.

[30]: T. Storcz, Z. Ercsey, K. R. Horváth, Z. Kovács, B. Dávid, and I. Kistelegdi, “Energy Design Synthesis: algorithmic generation of building shape configurations,” *Energies (Basel)*, vol. III, no. Thermal Behaviour, Energy Efficiency in Buildings and Sustainable Construction, 2023. doi: <https://doi.org/10.3390/en16052254>.

[103]: K. R. Horváth, Z. Ercsey, T. Storcz, Z. Kovács, and I. Kistelegdi, “Extension of the Energia Design Methodology to Algorithmic Geometry Generation and Prediction Models,” in *Abstract book for the 17th MIKLÓS IVÁNYI INTERNATIONAL PHD & DLA SYMPOSIUM: ARCHITECTURAL, ENGINEERING AND INFORMATION SCIENCES*, 2021, pp. 227–2235.

II. Tézis

A szimulációs adatok csoportosító elemzésével kimutattam, hogy a geometriai konfiguráció az épület energetikai és komfort teljesítményének meghatározása szempontjából lényeges komponens, azt a tervezés során figyelembe kell venni.

- a. Igazoltam, hogy a minimális fűtési energiaigényt a rossz konfiguráció választás akár 60%-kal növelheti.
- b. Igazoltam, hogy a termikus komfort a rossz konfiguráció választással akár 62%-kal csökkenhet.

[6]: I. Kistelegdi, K. R. Horváth, T. Storcz, and Z. Ercsey, “Building Geometry as a Variable in Energy, Comfort, and Environmental Design Optimization—A Review from the Perspective of Architects,” *Buildings*, vol. 12, no. 1, 2022, doi: 10.3390/buildings12010069.

[77]: T. Storcz, I. Kistelegdi, K. R. Horváth, and Z. Ercsey, “Applicability of Multivariate Linear Regression in Building Energy Demand Estimation,” *Mathematical Modelling of Engineering Problems*, vol. 9, no. 6, pp. 1451–1458, Dec. 2022, doi: 10.18280/mmep.090602.

[102]: N. Vincze, K. R. Horváth, I. Kistelegdi, T. Storcz, and Z. Ercsey, “DISTANCE MEASURES IN MORRIS METHOD FOR GLOBAL SENSITIVITY ANALYSIS SUPPORTING BUILDING OPTIMISATION,” *Pollack Periodica*, Submitted, 2023.

[104]: T. Storcz, N. Vincze, I. Kistelegdi, and Z. Ercsey, “Effects of building shape on energy demands and comfort,” *Folyamatban*, 2023.

[105]: I. Kistelegdi, Z. Ercsey, T. Storcz, and A. J. Gall, “Sensitivity Analysis of Building Comfort and Energy Design Variables,” in *IEEE 21st World Symposium on Applied Machine Intelligence and Informatics SAMI*, 2023, pp. 17–20.

III. Tézis

Bemutattam, hogy készíthető az épület konfigurációt, mint tervezési változót felhasználó energiaigény és komfortszint becslésre alkalmas adatvezérelt gépi tanuló regressziós modell, melynek leghatékonyabb épület konfiguráció leíró bemenete az általam javasolt moduláris épületterv diszkrét, funkcionális 3D reprezentációja.

- a. Kialakítottam egy, a teljes keresési teret leíró diszkrét funkcionális 3D reprezentációt.
- b. Kidolgoztam egy új eljárást, melyben elsőként alkalmaztam dinamikus épületkonfigurációs adatokat is felhasználó regressziós modelleket energetikai és komfort szimulációk helyettesítésére.
- c. Széleskörű parametrikus vizsgálattal igazoltam, hogy a (III.a tézispontban) bemutatott direkt leíró a vizsgált leírók közül a leghatékonyabb.
- d. Megállapítottam, hogy a szakértők által készített indirekt leíróknál jobb indirekt konfiguráció leíró is meghatározható, mivel a feature extrakciót automatikusan végző, (III.a tézispontban) bemutatott direkt konfigurációt leíró alkalmazó gépi tanuló modell a korábbiaknál jobb eredményt ért el.

[106]: T. Storcz, V. Géza, I. Kistelegdi, and Z. Ercsey, “Regression Models and Shape Descriptors for Building Energy Demand and Comfort Estimation,” *Energies (Basel)*, vol. 16, no. Energy Efficiency of the Buildings II, 2023. doi: <https://doi.org/10.3390/en16165896>.

[107]: T. Storcz, I. Kistelegdi, and Z. Ercsey, “Building energy demand regression,” in *Proceedings of the 25th International Multiconference INFORMATION SOCIETY Volume I: Middle-European Conference on Applied Theoretical Computer Science*, 2022, pp. 46–49.

[108]: T. Storcz, I. Kistelegdi, and Z. Ercsey, “Optimizing neural networks for building energy demand estimation,” in *IRIC 2022: Rethinking buildings and materials for a sustainable future*, 2022, pp. 29–37.

Az eredményeim felhasználásával lehetővé válik az épületkonfiguráció felhasználása dinamikus tervezési, optimalizációs változóként.

Továbbfejlesztés lehetőségei

- A. A moduláris térszervezés felbontásának javításával, a modulok funkcióinak bővítésével az energetikai vizsgálatokba bevont épülettípusok, valamint a vizsgált konfigurációk köre bővíthető. Ehhez szükséges a generált modulkötegek validációs eljárásának általánosítása, esetleg fuzzy vagy gépi tanuló alapokra helyezése is.
- B. A III.a altézisben bemutatott leíró továbbfejlesztéseként a modell által kialakított indirekt leírók, illetve a kialakítási eljárás további vizsgálata és szakértői értelmezése segíthet az épületforma és energetikai valamint komfort teljesítmény összefüggésének megértésében, megfogalmazásában.
- C. III. és B alapján ehhez kombinált neurális hálózat struktúra kialakítása és speciális tanulási eljárás megfogalmazása jó fejlesztési irány lehet, amelyben az épület modulok térgeometriai összefüggéseit egy 3D konvolúciós hálózati komponens határozza meg. Az így kialakuló 3D konvolúciós kernelek és azok előrecsatolt súlyai megkönnyíthetik a lokális geometriai összefüggések azonosítását és alkalmazásuk jellegének meghatározását.
- D. A bemutatott eljárások rendszere alkalmas az EDS folyamatba történő integrációra, ezért az EDS technológia ebbe az irányba javaslom fejleszteni.

Irodalomjegyzék

- [1] European Communities, “Directive 2002/91/EC of the European Parliament and of the Council of 16 December 2002 on the energy performance of buildings,” *Official Journal of the European Communities*, vol. 46, no. L1, pp. 65–71, Jan. 2003.
- [2] X. Cao, X. Dai, and J. Liu, “Building energy-consumption status worldwide and the state-of-the-art technologies for zero-energy buildings during the past decade,” *Energy Build*, vol. 128, pp. 198–213, Sep. 2016, doi: 10.1016/J.ENBUILD.2016.06.089.
- [3] G. Hausladen, M. de Saldanha, P. Liedl, and C. Sager, *Climate Design : Solutions for Buildings that Can Do More with Less Technology*. Basel: Birkhäuser Verlag, 2005.
- [4] S. Ji, B. Lee, and M. Y. Yi, “Building life-span prediction for life cycle assessment and life cycle cost using machine learning: A big data approach,” *Build Environ*, vol. 205, p. 108267, Nov. 2021, doi: 10.1016/j.buildenv.2021.108267.
- [5] B. Baranyai, B. Póth, and I. Kistelegdi, “Planning and research of smart buildings and constructions with the ‘Energydesign Roadmap’ method,” *Pollack Periodica*, vol. 8, no. 3, pp. 15–26, Dec. 2013, doi: 10.1556/Pollack.8.2013.3.2.
- [6] I. Kistelegdi, K. R. Horváth, T. Storcz, and Z. Ercsey, “Building Geometry as a Variable in Energy, Comfort, and Environmental Design Optimization—A Review from the Perspective of Architects,” *Buildings*, vol. 12, no. 1, 2022, doi: 10.3390/buildings12010069.
- [7] Y. Mert and N. Saygın, “Energy efficient building block design: An exergy perspective,” *Energy*, vol. 102, pp. 465–472, May 2016, doi: 10.1016/j.energy.2016.02.121.
- [8] V. Granadeiro, J. P. Duarte, J. R. Correia, and V. M. S. Leal, “Building envelope shape design in early stages of the design process: Integrating architectural design systems and energy simulation,” *Autom Constr*, vol. 32, pp. 196–209, Jul. 2013, doi: 10.1016/j.autcon.2012.12.003.

- [9] B. Kiss and Z. Szalay, “Modular approach to multi-objective environmental optimization of buildings,” *Autom Constr*, vol. 111, p. 103044, Mar. 2020, doi: 10.1016/J.AUTCON.2019.103044.
- [10] P. Depecker, C. Menezo, J. Virgone, and S. Lepers, “Design of buildings shape and energetic consumption,” *Build Environ*, vol. 36, no. 5, pp. 627–635, Jun. 2001, doi: 10.1016/S0360-1323(00)00044-5.
- [11] C. Ionescu, T. Baracu, G. E. Vlad, H. Necula, and A. Badea, “The historical evolution of the energy efficient buildings,” *Renewable and Sustainable Energy Reviews*, vol. 49, pp. 243–253, Sep. 2015, doi: 10.1016/j.rser.2015.04.062.
- [12] J. Wright, “The optimised design of HVAC systems,” Loughborough University, 1986.
- [13] A. T. Nguyen, S. Reiter, and P. Rigo, “A review on simulation-based optimization methods applied to building performance analysis,” *Appl Energy*, vol. 113, pp. 1043–1058, Jan. 2014, doi: 10.1016/J.APENERGY.2013.08.061.
- [14] S. M. Bambrook, A. B. Sproul, and D. Jacob, “Design optimisation for a low energy home in Sydney,” *Energy Build*, vol. 43, no. 7, pp. 1702–1711, Jul. 2011, doi: 10.1016/j.enbuild.2011.03.013.
- [15] A. T. Nguyen and S. Reiter, “Passive designs and strategies for low-cost housing using simulation-based optimization and different thermal comfort criteria,” *J Build Perform Simul*, vol. 7, no. 1, pp. 68–81, Jan. 2014, doi: 10.1080/19401493.2013.770067.
- [16] L. G. Caldas and L. K. Norford, “Genetic Algorithms for Optimization of Building Envelopes and the Design and Control of HVAC Systems,” *J Sol Energy Eng*, vol. 125, no. 3, pp. 343–351, Aug. 2003, doi: 10.1115/1.1591803.
- [17] C. Waibel, R. Evins, and J. Carmeliet, “Co-simulation and optimization of building geometry and multi-energy systems: Interdependencies in energy supply, energy demand and solar potentials,” *Appl Energy*, vol. 242, pp. 1661–1682, May 2019, doi: 10.1016/J.APENERGY.2019.03.177.

- [18] E. Saratsis, T. Dogan, and C. F. Reinhart, "Simulation-based daylighting analysis procedure for developing urban zoning rules," *Building Research & Information*, vol. 45, no. 5, pp. 478–491, Jul. 2017, doi: 10.1080/09613218.2016.1159850.
- [19] J. Michalek, R. Choudhary, and P. Papalambros, "Architectural layout design optimization," *Engineering Optimization*, vol. 34, no. 5, pp. 461–484, Jan. 2002, doi: 10.1080/03052150214016.
- [20] V. J. L. Gan, H. K. Wong, K. T. Tse, J. C. P. Cheng, I. M. C. Lo, and C. M. Chan, "Simulation-based evolutionary optimization for energy-efficient layout plan design of high-rise residential buildings," *J Clean Prod*, vol. 231, pp. 1375–1388, Sep. 2019, doi: 10.1016/j.jclepro.2019.05.324.
- [21] K. Javanroodi, V. M. Nik, and M. Mahdavinejad, "A novel design-based optimization framework for enhancing the energy efficiency of high-rise office buildings in urban areas," *Sustain Cities Soc*, vol. 49, p. 101597, Aug. 2019, doi: 10.1016/j.scs.2019.101597.
- [22] D. Tuhus-Dubrow and M. Krarti, "Genetic-algorithm based approach to optimize building envelope design for residential buildings," *Build Environ*, vol. 45, no. 7, pp. 1574–1581, Jul. 2010, doi: 10.1016/j.buildenv.2010.01.005.
- [23] F. Boithias, M. El Mankibi, and P. Michel, "Genetic algorithms based optimization of artificial neural network architecture for buildings' indoor discomfort and energy consumption prediction," *Build Simul*, vol. 5, no. 2, pp. 95–106, Jun. 2012, doi: 10.1007/S12273-012-0059-6.
- [24] Y. Bichiou and M. Krarti, "Optimization of envelope and HVAC systems selection for residential buildings," *Energy Build*, vol. 43, no. 12, pp. 3373–3382, Dec. 2011, doi: 10.1016/j.enbuild.2011.08.031.
- [25] W. Wang, H. Rivard, and R. Zmeureanu, "Floor shape optimization for green building design," *Advanced Engineering Informatics*, vol. 20, no. 4, pp. 363–378, Oct. 2006, doi: 10.1016/j.aei.2006.07.001.
- [26] Y. K. Yi and A. M. Malkawi, "Optimizing building form for energy performance based on hierarchical geometry relation," *Autom Constr*, vol. 18, no. 6, pp. 825–833, Oct. 2009, doi: 10.1016/j.autcon.2009.03.006.

- [27] C. R. Reeves, “Genetic Algorithms,” in *Handbook of Metaheuristics*, M. Gendreau and J.-Y. Potvin, Eds., New York: Springer New York, NY, 2010, pp. 109–139. doi: 10.1007/978-1-4419-1665-5_5.
- [28] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 4th ed. Upper Saddle River: Prentice Hall Press, 2022.
- [29] H. A. Priestley and M. P. Ward, “A Multipurpose Backtracking Algorithm,” *J Symb Comput*, vol. 18, no. 1, pp. 1–40, Jul. 1994, doi: 10.1006/JSCO.1994.1035.
- [30] T. Storcz, Z. Ercsey, K. R. Horváth, Z. Kovács, B. Dávid, and I. Kistelegdi, “Energy Design Synthesis: algorithmic generation of building shape configurations,” *Energies (Basel)*, vol. III, no. Thermal Behaviour, Energy Efficiency in Buildings and Sustainable Construction, Feb. 2023, doi: <https://doi.org/10.3390/en16052254>.
- [31] T. M. Mitchel, *Machine-learning*. McGraw-Hill, 1997.
- [32] A. Alrobaie and M. Krarti, “A Review of Data-Driven Approaches for Measurement and Verification Analysis of Building Energy Retrofits,” *Energies (Basel)*, vol. 15, no. 21, p. 7824, Oct. 2022, doi: 10.3390/en15217824.
- [33] K. Bamdad, M. E. Cholette, and J. Bell, “Building energy optimization using surrogate model and active sampling,” *J Build Perform Simul*, vol. 13, no. 6, pp. 760–776, Nov. 2020, doi: 10.1080/19401493.2020.1821094.
- [34] G. R. Araújo, R. Gomes, M. G. Gomes, M. C. Guedes, and P. Ferrão, “Surrogate Models for Efficient Multi-Objective Optimization of Building Performance,” *Energies (Basel)*, vol. 16, no. 10, p. 4030, May 2023, doi: 10.3390/en16104030.
- [35] H. Zhang, H. Feng, K. Hewage, and M. Arashpour, “Artificial Neural Network for Predicting Building Energy Performance: A Surrogate Energy Retrofits Decision Support Framework,” *Buildings*, vol. 12, no. 6, p. 829, Jun. 2022, doi: 10.3390/buildings12060829.
- [36] G. Ciulla and A. D’Amico, “Building energy performance forecasting: A multiple linear regression approach,” *Appl Energy*, vol. 253, p. 113500, Nov. 2019, doi: 10.1016/j.apenergy.2019.113500.

- [37] C. Peña-Guzmán and J. Rey, “Forecasting residential electric power consumption for Bogotá Colombia using regression models,” *Energy Reports*, vol. 6, pp. 561–566, Feb. 2020, doi: 10.1016/J.EGYR.2019.09.026.
- [38] A. Mohammed, A. Alshibani, O. Alshamrani, and M. Hassanain, “A regression-based model for estimating the energy consumption of school facilities in Saudi Arabia,” *Energy Build*, vol. 237, p. 110809, Apr. 2021, doi: 10.1016/J.ENBUILD.2021.110809.
- [39] V. Bianco, O. Manca, and S. Nardini, “Linear Regression Models to Forecast Electricity Consumption in Italy,” *Energy Sources, Part B: Economics, Planning, and Policy*, vol. 8, no. 1, pp. 86–93, Jan. 2013, doi: 10.1080/15567240903289549.
- [40] F. Tahmasebinia, R. Jiang, S. Sepasgozar, J. Wei, Y. Ding, and H. Ma, “Using Regression Model to Develop Green Building Energy Simulation by BIM Tools,” *Sustainability*, vol. 14, no. 10, p. 6262, May 2022, doi: 10.3390/su14106262.
- [41] A. Mehedintu, M. Sterpu, and G. Soava, “Estimation and forecasts for the share of renewable energy consumption in final energy consumption by 2020 in the European Union,” *Sustainability (Switzerland)*, vol. 10, no. 5, May 2018, doi: 10.3390/su10051515.
- [42] R. Tibshirani, “Regression Shrinkage and Selection via the Lasso,” *Journal of the Royal Statistical Society. Series B*, vol. 58, no. 1, pp. 267–288, 1996.
- [43] F. Emmert-Streib and M. Dehmer, “High-Dimensional LASSO-Based Computational Regression Models: Regularization, Shrinkage, and Selection,” *Mach Learn Knowl Extr*, vol. 1, no. 1, pp. 359–383, Jan. 2019, doi: 10.3390/make1010021.
- [44] A. E. Hoerl and R. W. Kennard, “Ridge Regression: Applications to Nonorthogonal Problems,” *Technometrics*, vol. 12, no. 1, p. 69, Feb. 1970, doi: 10.2307/1267352.
- [45] H. Midi and M. Zahari, “A Simulation Study On Ridge Regression Estimators In The Presence Of Outliers And Multicollinearity,” *J Teknol*, vol. 47, no. 1, Dec. 2007, doi: 10.11113/jt.v47.261.

- [46] W. Loh, “Classification and regression trees,” *WIREs Data Mining and Knowledge Discovery*, vol. 1, no. 1, pp. 14–23, Jan. 2011, doi: 10.1002/widm.8.
- [47] R. Blanquero, E. Carrizosa, C. Molero-Río, and D. R. Morales, “On sparse optimal regression trees,” *Eur J Oper Res*, vol. 299, no. 3, pp. 1045–1054, Jun. 2022, doi: 10.1016/j.ejor.2021.12.022.
- [48] Z. Yu, F. Haghghat, B. C. M. Fung, and H. Yoshino, “A decision tree method for building energy demand modeling,” *Energy Build*, vol. 42, no. 10, pp. 1637–1646, Oct. 2010, doi: 10.1016/j.enbuild.2010.04.006.
- [49] A. Galicia, R. Talavera-Llames, A. Troncoso, I. Koprinska, and F. Martínez-Álvarez, “Multi-step forecasting for big data time series based on ensemble learning,” *Knowl Based Syst*, vol. 163, pp. 830–841, Jan. 2019, doi: 10.1016/j.knosys.2018.10.009.
- [50] N. J. Guliyev and V. E. Ismailov, “On the approximation by single hidden layer feedforward neural networks with fixed weights,” *Neural Networks*, vol. 98, pp. 296–304, Feb. 2018, doi: 10.1016/j.neunet.2017.12.007.
- [51] D. Tikk, L. T. Kóczy, and T. D. Gedeon, “A survey on universal approximation and its limits in soft computing techniques,” *International Journal of Approximate Reasoning*, vol. 33, no. 2, pp. 185–202, Jun. 2003, doi: 10.1016/S0888-613X(03)00021-5.
- [52] P. Kidger, T. Lyons, J. Abernethy, and S. Agarwal, “Universal Approximation with Deep Narrow Networks,” 2020.
- [53] O. A. Manita, M. A. Peletier, J. W. Portegies, J. Sanders, and A. Senen-Cerda, “Universal Approximation in Dropout Neural Networks,” 2022. [Online]. Available: <http://jmlr.org/papers/v23/20-1433.html>.
- [54] K. Hornik, M. Stinchcombe, and H. White, “Multilayer feedforward networks are universal approximators,” *Neural Networks*, vol. 2, no. 5, pp. 359–366, Jan. 1989, doi: 10.1016/0893-6080(89)90020-8.
- [55] D. F. Specht, “A general regression neural network,” *IEEE Trans Neural Netw*, vol. 2, no. 6, pp. 568–576, Nov. 1991, doi: 10.1109/72.97934.

- [56] T. Storcz and Z. Ercsey, "Detection of feature-poor, small sized objects on noisy images," *Pollack Periodica*, vol. 17, no. 1, 2022, doi: 10.1556/606.2021.00425.
- [57] A. Dhillon and G. K. Verma, "Convolutional neural network: a review of models, methodologies and applications to object detection," *Progress in Artificial Intelligence*, vol. 9, no. 2, pp. 85–112, Jun. 2020, doi: 10.1007/s13748-019-00203-0.
- [58] S. Indolia, A. K. Goswami, S. P. Mishra, and P. Asopa, "Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach," *Procedia Comput Sci*, vol. 132, pp. 679–688, 2018, doi: 10.1016/j.procs.2018.05.069.
- [59] D.-X. Zhou, "Universality of deep convolutional neural networks," *Appl Comput Harmon Anal*, vol. 48, no. 2, pp. 787–794, Mar. 2020, doi: 10.1016/j.acha.2019.06.004.
- [60] R. DiPietro and G. D. Hager, "Deep learning: RNNs and LSTM," in *Handbook of Medical Image Computing and Computer Assisted Intervention*, Elsevier, 2020, pp. 503–519. doi: 10.1016/B978-0-12-816176-0.00026-0.
- [61] P. RODRIGUEZ, J. WILES, and J. L. ELMAN, "A Recurrent Neural Network that Learns to Count," *Conn Sci*, vol. 11, no. 1, pp. 5–40, Mar. 1999, doi: 10.1080/095400999116340.
- [62] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [63] J. A. Pérez-Ortiz, F. A. Gers, D. Eck, and J. Schmidhuber, "Kalman filters improve LSTM network performance in problems unsolvable by traditional recurrent nets," *Neural Networks*, vol. 16, no. 2, pp. 241–250, Mar. 2003, doi: 10.1016/S0893-6080(02)00219-8.
- [64] A. E. Ben-Nakhi and M. A. Mahmoud, "Cooling load prediction for buildings using general regression neural networks," *Energy Convers Manag*, vol. 45, no. 13–14, pp. 2127–2141, Aug. 2004, doi: 10.1016/j.enconman.2003.10.009.
- [65] D. A. Pisner and D. M. Schnyer, "Support vector machine," in *Machine Learning*, Elsevier, 2020, pp. 101–121. doi: 10.1016/B978-0-12-815739-8.00006-7.

- [66] H. Xu, C. Caramanis, and S. Mannor, “Robustness and Regularization of Support Vector Machines,” Mar. 2008, doi: 10.48550/arXiv.0803.3490.
- [67] P. Nie, M. Roccotelli, M. P. Fanti, Z. Ming, and Z. Li, “Prediction of home energy consumption based on gradient boosting regression tree,” *Energy Reports*, vol. 7, pp. 1246–1255, Nov. 2021, doi: 10.1016/j.egy.2021.02.006.
- [68] M. Zekić-Sušac, A. Has, and M. Knežević, “Predicting energy cost of public buildings by artificial neural networks, CART, and random forest,” *Neurocomputing*, vol. 439, pp. 223–233, Jun. 2021, doi: 10.1016/j.neucom.2020.01.124.
- [69] M. B. Kurska and W. R. Rudnicki, “Feature Selection with the Boruta Package,” *J Stat Softw*, vol. 36, no. 11, 2010, doi: 10.18637/jss.v036.i11.
- [70] W. Mounter, C. Ogwumike, H. Dawood, and N. Dawood, “Machine Learning and Data Segmentation for Building Energy Use Prediction—A Comparative Study,” *Energies (Basel)*, vol. 14, no. 18, p. 5947, Sep. 2021, doi: 10.3390/en14185947.
- [71] A. Attanasio, M. Piscitelli, S. Chiusano, A. Capozzoli, and T. Cerquitelli, “Towards an Automated, Fast and Interpretable Estimation Model of Heating Energy Demand: A Data-Driven Approach Exploiting Building Energy Certificates,” *Energies (Basel)*, vol. 12, no. 7, p. 1273, Apr. 2019, doi: 10.3390/en12071273.
- [72] S. R. Mohandes, X. Zhang, and A. Mahdiyar, “A comprehensive review on the application of artificial neural networks in building energy analysis,” *Neurocomputing*, vol. 340, pp. 55–75, May 2019, doi: 10.1016/j.neucom.2019.02.040.
- [73] F. U. M. Ullah, A. Ullah, I. U. Haq, S. Rho, and S. W. Baik, “Short-Term Prediction of Residential Power Energy Consumption via CNN and Multi-Layer Bi-Directional LSTM Networks,” *IEEE Access*, vol. 8, pp. 123369–123380, 2020, doi: 10.1109/ACCESS.2019.2963045.
- [74] B. W. Kernighan and D. M. Ritchie, *C Programming Language*, 2nd ed. Pearson, 1988.
- [75] M. Lutz, *Learning Python*, 5th ed. O’Reilly Media, 2013.

- [76] M. Lutz, *Programming Python: Powerful Object-Oriented Programming*, 4th ed. O'Reilly Media, 2011.
- [77] T. Storcz, I. Kistelegdi, K. R. Horváth, and Z. Ercsey, “Applicability of Multivariate Linear Regression in Building Energy Demand Estimation,” *Mathematical Modelling of Engineering Problems*, vol. 9, no. 6, pp. 1451–1458, Dec. 2022, doi: 10.18280/mmep.090602.
- [78] K. R. Horváth, “Energia Design Szintézis-Az Energia Design módszertan kiterjesztése algoritmikus geometria generáló és predikciós modellek felhasználásával,” Pécsi Tudományegyetem, Pécs, 2021.
- [79] U. T. Aksoy and M. Inalli, “Impacts of some building passive design parameters on heating demand for a cold region,” *Build Environ*, vol. 41, no. 12, pp. 1742–1754, Dec. 2006, doi: 10.1016/j.buildenv.2005.07.011.
- [80] J. Parasonis, A. Keizikas, A. Endriukaitytė, and D. Kalibatienė, “ARCHITECTURAL SOLUTIONS TO INCREASE THE ENERGY EFFICIENCY OF BUILDINGS / ARCHITEKTŪROS SPRENDINIAI, DIDINANTYS ENERGINĮ PASTATŲ EFEKTYVUMĄ,” *Journal of Civil Engineering and Management*, vol. 18, no. 1, pp. 71–80, Feb. 2012, doi: 10.3846/13923730.2011.652983.
- [81] J. F. Kenney and E. S. Keeping, “Linear Regression and Correlation,” in *Mathematics of statistics 1*, 3rd ed. Princeton: Van Nostrand, 1962.
- [82] D. J. Olive, *Linear Regression*. Cham: Springer International Publishing, 2017. doi: 10.1007/978-3-319-55252-1.
- [83] A. C. Cameron and F. A. G. Windmeijer, “An R-squared measure of goodness of fit for some common nonlinear regression models,” *J Econom*, vol. 77, no. 2, pp. 329–342, Apr. 1997, doi: 10.1016/S0304-4076(96)01818-0.
- [84] S. S. SHAPIRO and M. B. WILK, “An analysis of variance test for normality (complete samples),” *Biometrika*, vol. 52, no. 3–4, pp. 591–611, Dec. 1965, doi: 10.1093/biomet/52.3-4.591.
- [85] R. B. D’AGOSTINO, “Transformation to normality of the null distribution of g_1 ,” *Biometrika*, vol. 57, no. 3, pp. 679–681, 1970, doi: 10.1093/biomet/57.3.679.

- [86] T. W. Anderson and D. A. Darling, “Asymptotic Theory of Certain ‘Goodness of Fit’ Criteria Based on Stochastic Processes,” *The Annals of Mathematical Statistics*, vol. 23, no. 2, pp. 193–212, Jun. 1952, doi: 10.1214/aoms/1177729437.
- [87] N. Smirnov, “Table for Estimating the Goodness of Fit of Empirical Distributions,” *The Annals of Mathematical Statistics*, vol. 19, no. 2, pp. 279–281, Jun. 1948, doi: 10.1214/aoms/1177730256.
- [88] F. M. Dekking, C. Kraaikamp, H. P. Lopuhaä, and L. E. Meester, *A Modern Introduction to Probability and Statistics*. London: Springer London, 2005. doi: 10.1007/1-84628-168-7.
- [89] R. R. Wilcox, *Introduction to Robust Estimation and Hypothesis Testing*. Elsevier, 2021. doi: 10.1016/C2019-0-01225-3.
- [90] Y. Tian, Y. Zhang, and H. Zhang, “Recent Advances in Stochastic Gradient Descent in Deep Learning,” *Mathematics*, vol. 11, no. 3, p. 682, Jan. 2023, doi: 10.3390/math11030682.
- [91] Z. Zhang, “Improved Adam Optimizer for Deep Neural Networks,” in *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*, IEEE, Jun. 2018, pp. 1–2. doi: 10.1109/IWQoS.2018.8624183.
- [92] M. R. Hestenes and E. Stiefel, “Methods of conjugate gradients for solving linear systems,” *J Res Natl Bur Stand (1934)*, vol. 49, no. 6, p. 409, Dec. 1952, doi: 10.6028/jres.049.044.
- [93] Y. Notay, “Flexible Conjugate Gradients,” *SIAM Journal on Scientific Computing*, vol. 22, no. 4, pp. 1444–1460, Jan. 2000, doi: 10.1137/S1064827599362314.
- [94] D. F. Shanno, “Conditioning of quasi-Newton methods for function minimization,” *Math Comput*, vol. 24, no. 111, pp. 647–656, 1970, doi: 10.1090/S0025-5718-1970-0274029-X.
- [95] R. Fletcher, “A new approach to variable metric algorithms,” *Comput J*, vol. 13, no. 3, pp. 317–322, Mar. 1970, doi: 10.1093/comjnl/13.3.317.

- [96] R. H. Byrd, P. Lu, J. Nocedal, and C. Zhu, “A Limited Memory Algorithm for Bound Constrained Optimization,” *SIAM Journal on Scientific Computing*, vol. 16, no. 5, pp. 1190–1208, Sep. 1995, doi: 10.1137/0916069.
- [97] K. C. Kiwiel, “Convergence and efficiency of subgradient methods for quasiconvex minimization,” *Math Program*, vol. 90, no. 1, pp. 1–25, Mar. 2001, doi: 10.1007/PL00011414.
- [98] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986, doi: 10.1038/323533a0.
- [99] B. T. Polyak and A. B. Juditsky, “Acceleration of Stochastic Approximation by Averaging,” *SIAM J Control Optim*, vol. 30, no. 4, pp. 838–855, Jul. 1992, doi: 10.1137/0330046.
- [100] H. Abdi and L. J. Williams, “Principal component analysis,” *Wiley Interdiscip Rev Comput Stat*, vol. 2, no. 4, pp. 433–459, Jul. 2010, doi: 10.1002/wics.101.
- [101] P. Heiselberg, H. Brohus, A. Hesselholt, H. Rasmussen, E. Seinre, and S. Thomas, “Application of sensitivity analysis in design of sustainable buildings,” *Renew Energy*, vol. 34, no. 9, pp. 2030–2036, Sep. 2009, doi: 10.1016/j.renene.2009.02.016.
- [102] N. Vincze, K. R. Horváth, I. Kistelegdi, T. Storcz, and Z. Ercsey, “DISTANCE MEASURES IN MORRIS METHOD FOR GLOBAL SENSITIVITY ANALYSIS SUPPORTING BUILDING OPTIMISATION,” *Pollack Periodica*, vol. Submitted, 2023.
- [103] K. R. Horváth, Z. Ercsey, T. Storcz, Z. Kovács, and I. Kistelegdi, “Extension of the Energia Design Methodology to Algorithmic Geometry Generation and Prediction Models,” in *Abstract book for the 17th MIKLÓS IVÁNYI INTERNATIONAL PHD & DLA SYMPOSIUM: ARCHITECTURAL, ENGINEERING AND INFORMATION SCIENCES*, P. Iványi, Ed., Pécs: Pollack Press, 2021, pp. 227–235.
- [104] T. Storcz, N. Vincze, I. Kistelegdi, and Z. Ercsey, “Effects of building shape on energy demands and comfort,” *Folyamatban*, 2023.

- [105] I. Kistelegdi, Z. Ercsey, T. Storcz, and A. J. Gall, “Sensitivity Analysis of Building Comfort and Energy Design Variables,” in *IEEE 21st World Symposium on Applied Machine Intelligence and Informatics SAMI*, A. Szakál, Ed., Herlany, 2023, pp. 17–20.
- [106] T. Storcz, V. Géza, I. Kistelegdi, and Z. Ercsey, “Regression Models and Shape Descriptors for Building Energy Demand and Comfort Estimation,” *Energies (Basel)*, vol. 16, no. Energy Efficiency of the Buildings II, 2023, doi: 10.3390/en16165896.
- [107] T. Storcz, I. Kistelegdi, and Z. Ercsey, “Building energy demand regression,” in *Proceedings of the 25th International Multiconference INFORMATION SOCIETY Volume I: Middle-European Conference on Applied Theoretical Computer Science*, A. Brodni, G. Galambos, and B. Kavsek, Eds., Ljubljana: Institut Jožef Stefan, 2022, pp. 46–49.
- [108] T. Storcz, I. Kistelegdi, and Z. Ercsey, “Optimizing neural networks for building energy demand estimation,” in *IRIC 2022: Rethinking buildings and materials for a sustainable future*, G. Fábíán, Ed., Koper: Innorenew CoE, University of Primorska Press, 2022, pp. 29–37.

Köszönetnyilvánítás

Köszönöm témavezetőmnek, Dr. Várady Gézának a szakmai és adminisztrációs segítségét, valamint a megfelelő tudományos fórumokon való publikálási lehetőségek biztosítását.

Köszönöm Dr. Kistelegdi Istvánnak az energetikai szimulációk elvégzését, építészeti tématerületen nyújtott segítségét a kutatások peremfeltételeinek meghatározásában és az eredményeim építészeti értelmezésében.

Köszönöm Dr. Iványi Péternek a kutatások elvégzéséhez szükséges technikai feltételek biztosítását.

Köszönöm Müller Péternek és Schäffer Zsoltnak az inspiráló szakmai beszélgetéseket.

Külön köszönöm Dr. Ercsey Zsolt széleskörű és kitartó támogatását, nélküle nem sikerült volna.

Végül, de nem utolsósorban köszönöm családomnak a szeretetet és megértést.

A kutatás a Pécsi Tudományegyetem Műszaki és Informatikai Kar támogatásával valósult meg.

Pécs, 2023. február 27.

Storcz Tamás László

Összefoglalás

Európa elsődleges energia felhasználásának több mint 40%-a épületeink létrehozására és üzemeltetésére vezethető vissza. Mivel ez igaz az energia előállításánál keletkező CO₂ kibocsátásra is, az ilyen célú energiafelhasználás csökkentése egyaránt gazdasági és környezetvédelmi elvárás is. Kutatásom célja az Energia Design módszer bővítéseként bemutatott Energia Design Szintézis (Energy Design Synthesis - EDS) eljárás támogatása a legjobb energia és komfort teljesítménnyel rendelkező épületforma (konfiguráció) meghatározása során.

Dolgozatom az EDS első két lépését, a megvalósítható épületek kiválasztását és a komplex szimulációk elvégzését támogatja. Ennek keretében egy jól alkalmazható épületkonfiguráció leíró eljárás meghatározása, az összes konfiguráció előállítása, ezekből az építészeti feltételeknek is megfelelők kiválasztása, majd az elfogadottakhoz tartozó komplex energetikai (fűtés, hűtés, világítás) és komfort (hőérzet, megvilágítás) szimulációk gyors becslésére regressziós eljárások készítése, teljesítményük elemzése és a helyettesítésükre alkalmasak (surrogate model) kiválasztása történt meg.

Az optimális megoldás kiválasztása során figyelembe vett teljesítményeket nem szükséges az összes elfogadható épületformára előállítani. Az I. tézisem felhasználásával az azonos energetikai és komfortteljesítménnyel rendelkező konfigurációk halmazainak meghatározása után ezeket a halmazokat elegendő egy tetszőleges elemükkel reprezentálni. Így az optimum meghatározása kevesebb elem teljesítmény becslésével, majd a legjobb kiválasztásával történik. Az épületforma tervezési változóként történő figyelembevételének fontosságát a II. tézisemben fogalmazom meg. Az épületkonfiguráció tervezési változóként történő felhasználását biztosító reprezentációt és az azt felhasználó surrogate modelleket a III. tézisem keretében mutatom be.

Jelen munkámban az épületkonfiguráció optimalizáció még nem teljes, a leghatékonyabb konfiguráció kiválasztása csak az egyes kimeneti adattípusok alapján külön végezhető. Ennek oka, hogy az energetikai és komfort teljesítmények értékelésének egy metrikába integrálása az építész és épületgépész tudományterületek jelenleg is kutatott témája.

Summary

Buildings produce more than 40% of the world's total energy consumption and CO₂-emissions due to construction and operation. Therefore reduction of such consumption is an economical and also an environmental expectation. The aim of my research is the extension of the Energy Design method used for building shape optimization to support the new Energy Design Synthesis (EDS) method. The purpose of EDS is the selection of building shape having the best energetic and comfort performance. For this reason, the proposed method creates all possible, acceptable building shapes (configurations) and simulates their energetic (heating, cooling, lighting) and comfort (thermal, illumination) performances. By analyzing complex simulation results, a performance ordered list is created. From this list, the best/optimal solution can be selected. The purpose of my dissertation is first, to prove that the building shape is a decisive component of energetic and comfort performance, then support the selection of architecturally acceptable building configurations to simulate and finally substitute complex simulations with data driven machine learning models. In the context of configuration acceptance, using the proposed building configuration descriptor and the formal description of architectural acceptance of configurations selection is done. To reduce the number of items to work with, based on my thesis (Thesis 1), sets of configurations having same energetic and comfort performance are replaced with their single, arbitrary element. As part of speeding up complex energetic and comfort simulations, regression models (linear, polynomial, decision tree based, neural network based) were created. Selection of applicable surrogate models were done based on measurement and analysis of their performance. The importance of using the building configuration (shape) as design variable is discussed in my thesis (Thesis 2). The best building configuration descriptors and simulation surrogate methods applying them is discussed in my thesis (Thesis 3). In my current work, the building configuration optimization is not complete, the most efficient building configuration can only be selected based on a single type of output (heating energy consumption, cooling energy consumption, lighting energy consumption, thermal comfort, illumination comfort). The reason is that integration of previously mentioned energetic and comfort performance evaluations into one measure is an open field of architectural and building engineering research.