

PÉCSI TUDOMÁNYEGYETEM



DOKTORI (PHD) - ÉRTEKEZÉS TÉZISEI

**Postmortem időtartam meghatározása dinamikusan
változó környezeti feltételek figyelembevételével**

Szerző:

Dani Livia Mária

Témavezetők:

Dr. Kozma Zsolt PhD

Dr. Frigyik B. András

Doktori iskola vezetője: Prof. Dr. Gallyas Ferenc

Programvezető: Prof. Dr. Nyitrai Miklós

Interdiszciplináris Orvostudományok Doktori Iskola (D93)
OGYDHT Pécs

2023

Interdiszciplináris Orvostudományok Doktori Iskola (D93)

Doktori iskola vezetője: Prof. Dr. Gallyas Ferenc

Program: Funkcionális fehérjedinamika vizsgálata biofizikai módszerekkel (B-130/1993)

Programvezető: Prof. Dr. Nyitrai Miklós

Témavezetők:

Dr. Kozma Zsolt PhD, egyetemi adjunktus

Pécsi Tudományegyetem Általános Orvostudományi Kar,
Igazságügyi Orvostani Intézet

Dr. Frigyik B. András, egyetemi docens

Óbudai Egyetem Bánki Donát Gépész és Biztonságtechnikai Mérnöki Kar,
Mechatronikai és Járműtechnikai Intézet

*„Semmi sem olyan biztos, mint a halál, és semmi sem
olyan bizonytalan, mint a halál órája.”*

Galgóczi Erzsébet

Bevezetés

A 19. századtól a fejlett országokban megkövetelték, hogy a halál bekövetkeztét orvos határozza meg. A halottvizsgálat során az orvos feladata a halál tényének, módjának és idejének a megállapítása, a hullajelenségek és a körülmények részletes vizsgálata alapján. A halál időintervallumának megállapítása az igazságügyi orvostan egyik legrégebben vizsgált kérdésköre, mely már kezdetektől kihívások elé állította a szakembereket és a mai napig jelentős kutatások tárgyát képezi.

Postmortem intervallum becslése

A halál bekövetkezését követően a testben különböző postmortem folyamatok indulnak el és mennek végbe, melyek a test hűléséhez, majd lebomlásához vezetnek: leálló anyagcsere, hullafoltok (livores mortuales), hullamerevség (rigor mortis), hűlés (algor mortis), bomlás (dekompozíció). A hűlési folyamat addig tart, míg a test hőmérséklete el nem éri a környezeti hőmérsékletet. A halál utáni testhőmérséklet meghatározására számos – különböző testrész hőmérsékletének mérésére épülő – módszer született az évszázadok során, például külső hallójárat, köpeny, agy, szem, máj vagy rektális hőmérséklet mérésével.

Az algor mortis sebességének mérése és megfigyelése fontos szerepet játszhat a postmortem intervallum¹ (PMI) becslésében. Ez a folyamat azonban csak becsült időintervallumokat ad, ezért bizonyos esetekben pontosabb eredményt csak más módszerekkel (rigor mortis és dekompozíció) kombinálva lehet adni a halál bekövetkezésének idejére.

Newton-féle hűlési törvény

Az első írásos eredmények az 1830-as évekből származnak. A 19. században végzett mérések döntő többsége köpenyhőmérsékletet mért eltérő skálájú hőmérőkkel. A problémát matematikai eszközök felhasználásával először Rainy [1] írta le, a Newton-féle lehűlési törvény segítségével, illetve megfogalmazta a hőmérsékleti plató létezését, melyet már előtte többen is megfigyeltek.

¹Az egyén halálának bekövetkezése óta eltelt idő.

A hővezetés alapegyenlete, a Newton-féle lehülési törvény: "A C_1 hőkapacitású, T_1 hőmérsékletű, A felületű test $C_2 \gg C_1$ hőkapacitású, s ennélfogva gyakorlatilag $T_2 = \text{állandó}$ hőmérsékletű környezetének dt idő alatt $dQ = C_1 dT$ hőt ad le."²

A Newton-féle hűlési törvény nem alkalmas a holttest hűlési folyamatának teljes matematikai leírására, mivel nem jellemzi a plató fázist.

Marshall-Hoare formula

Matematikai szempontból a problémakör jellemzésére új eredmény Marshall és Hoare nevéhez fűződik, akik 1962-ben megalkottak egy empirikus formulát, mely két exponenciális függvény lineáris kombinációjából áll, így alkalmas a szigmoid hűlési görbe matematikai jellemzésére. A Marshall-Hoare formula [2]–[4]:

$$\frac{T_r - T_a}{T_0 - T_a} = A \cdot \exp(Bt) + (1 - A) \cdot \exp\left(\frac{AB}{A - 1}t\right) \quad (1)$$

ahol T_r és T_a a t időpontban mért rektális és környezeti hőmérséklet, $T_0 = 37,2^\circ\text{C}$ állandó, mely a halál beálltakor mért rektális hőmérséklet. A formulában A és B empirikus úton kapott paraméterek, melyek értéke függ attól, hogy agy vagy végbél hőmérsékletet mérünk, ugyanis technikailag a formula alkalmas mindkét eset tárgyalására, csak más A és B értékekkel (1. táblázat).

	(a)	(b)
T_a	$\leq 23,2^\circ\text{C} \quad \geq 23,3^\circ\text{C}$	T_a 10–20,5°C
A	1,25 1,11	A 1,135
B	tömegtől függ	B -0,127

1. táblázat. A és B paraméterek értékei rektális (a) és agyi (b) hőmérséklet mérés esetén

Rektális hőmérsékletmérés esetén, B tartalmazza a testtömeget (m) vagyis:

$$B = -1,2815 \cdot m^{-0,625} + 0,0284 \quad (2)$$

A Marshall-Hoare formula a két hőmérsékleti tartományra rektális hőmérsékletmérés esetén a következő:

$T_a \leq 23,2^\circ\text{C}$:

$$\frac{T_r - T_a}{37,2 - T_a} = 1,25 \cdot \exp(Bt) - 0,25 \cdot \exp(5Bt) \quad (3)$$

$T_a \geq 23,3^\circ\text{C}$:

$$\frac{T_r - T_a}{37,2 - T_a} = 1,11 \cdot \exp(Bt) - 0,11 \cdot \exp(10Bt) \quad (4)$$

²Litz József: Fizika II. Termodinamika és molekuláris fizika - Elektromosság és mágnesesség (2005), 659. oldal

A halál időpontjának meghatározása, annak befolyásoló tényezőinek felkutatása további vizsgálatokat, módszereket és a Marshall-Hoare formula továbbfejlesztésének igényét jelentette.

Henssge formula

A Marshall-Hoare formula gyakorlatban történő bevezetése Henssge nevéhez fűződik [6], aki egy egyszerűsített módszert mutatott be a hűlési együttható meghatározására és bevezette a testtömegre vonatkozó empirikus korrekciós faktorokat [7]–[10]. Henssge a korrekciós faktorokat különböző darabszámú és vastagságú ruha rétegre és környezeti jellemzőre határozta meg, ezzel lehetővé tette, hogy ezen befolyásoló paramétereket figyelembe lehessen venni a PMI meghatározása során, ugyanis ezek módosíthatják az eredményül kapott értéket. A korrekciós faktorok esetében fontos megjegyezni, hogy értékük 0,75-től kezdődik és akár a 10,9-es értéket is elérheti, kiegészítő korrekcióra 1,4-es értéket felett szorul a testtömeg függvényében [10]. A korrekciós faktorról bővített Marshall-Hoare formula esetén a korrekció a becsült testtömegre vonatkozik, így a (2) összefüggésben leírt B paraméter a következőképpen változik:

$$B = -1,2815 \cdot (k \cdot m)^{-0,625} + 0,0284, \quad (5)$$


ahol k a Henssge által bevezetett korrekciós faktor. A (3)-os és a (4) formulákban leírt összefüggés nem változott Henssge módosításával, csak a B paraméter értékének kiszámolása.

Mivel a Henssge formulát a halál időintervallumának becsléséhez t -re oldjuk meg, így az egy transzcendens egyenlet, vagyis zárt alakban nem megoldható. Megoldásához vagy numerikus módszerre van szükség vagy egy grafikus megoldási módszerre, úgynevezett számoló ábrára vagy más néven nomogramra.

Henssge nomogram

A Marshall-Hoare/Henssge formula grafikus megoldásának módszerét Henssge [6] dolgozta ki, aki különböző nomogramokat (2. ábra) készített rektális hőmérsékletmérés esetén 23°C -os környezeti hőmérséklet alatti/feletti esetre, illetve külön nomogram készült az agy [11] hőmérsékletének mérésével történő számolásra is.

Mindkét nomogram esetén számolnunk kell bizonyos fokú bizonytalansággal a becsült időintervallum esetén, ez $T_a > 23^\circ\text{C}$ esetén korrekciós faktorról akár $\pm 2,8$, $\pm 4,5$, ± 7 óra is lehet, meztelen test esetén is $\pm 2,8$, $\pm 3,2$, $\pm 4,5$ órát is meghaladhatja, konfidencia intervalluma 95,45%.



1. ábra. Henssge formula[5]




Figure 2.37 Henssge's nomogram method for estimating the time since death from a single rectal temperature, where the environmental temperature is above 23°C.

2. ábra. Henssge nomogram 23 °C felett³

³Kép forrása: Pekka Saukko, Bernard Knight: Knight's Forensic Pathology (2015, 4. kiadás) 88. oldal

Célkitűzés

A tanulmány célja a PMI becslés során felmerülő befolyásoló tényezők feltárása, figyelembevételének lehetőségei.

A cél egy rugalmas matematikai modell létrehozása volt, mely könnyen adaptálható eltérő antropometriai jellemzőkkel rendelkező népcsoportokra, alkalmas lehet különböző geográfiai régiókban is, mivel kevés elemszámú tanító adattal specifikusan újra tanítható.

A kutatás során azt is vizsgáltam, hogy az eddig alkalmazott matematikai módszerekkel – Henssge módszer és annak numerikus megoldásai – mekkora hibával lehet becsülni a halál utáni időintervallumot. Ennek célja az volt, hogy összehasonlítsam a saját szintetikus modellem eredményeit, más megoldások eredményeivel.

A kutatás során megválaszolni kívánt kérdések

1. Melyik regressziós módszer adja a legjobb becslést?
2. Mennyi minimális tanító adat szüksége ahhoz, hogy a szintetikus modell alkalmazható legyen a PMI becslésére?
3. Mekkora a becslés várható hibája?
4. Mely esetekben nem alkalmazható a modell?
5. Hogyan lehet továbbfejleszteni a szintetikus modellt?

Szintetikus modellel végzett kísérletek és eredmények

A paraméterek becslésének matematikai tárgyalása felfogható úgy, mint egy lineáris regressziós probléma megoldása, ami alapján kapunk egy modellt, mely alkalmas a halál időintervallumának becslésére. Erre számos különböző matematikai eszköz közül választhatunk, melyek lehetnek különféle regressziós módszerek, döntési fák vagy neurális háló segítségével történő megoldás, mely során a cél egy adott tanulási halmazhoz legjobban illeszkedő valós függvény megtalálása. Egy speciális neurális hálózatnak tekinthető az SVM, mely felügyelt tanulási módszerek halmaza, amelyek alapvetően lineáris klasszifikálásra, regresszióra és kiugró értékek észlelésére használhatók. A döntési függvényekhez különböző kernelfüggvények adhatók meg. A kernel módszerek célja, hogy egy lineárisan megoldható problémát kapjunk, vagyis használatuk során a megoldandó feladatot leíró adatokat, nemlineáris transzformációk használatával egy transzformált térbe alakítjuk át, egy ilyen kernel például a radiális bázis-függvény (továbbiakban RBF).

A kitalált matematikai modell becslésének pontossága a viszonylag sok megadható paraméter helyességétől függ, mely alapján a rendszer megtanul mintát illeszteni az esetekre és a későbbiekben ez alapján döntést hozni, vagyis megbecsülni a halál időpontját olyan és ahhoz hasonló esetekben, melyekkel már találkozott.

A szintetikus modell alapjául több különböző regressziós eszközök használtam különböző beállításokkal és kerestem meg eszközönként is a legjobb paraméterezést, illetve ezt követően a matematikai eszközök együttes használatával még tovább javítottam a kapott eredményen. A vizsgált módszerek a következők voltak:

- regressziós fa,
- random forests,
- extrém módon randomizált fák,
- zsákolás módszerével módosított fa,
- SVR RBF kernellel,
- adaptív boostinggal javított SVR.

Tanítások eredményei

A felhasznált és különböző paraméterezéssel tesztelt regressziós eszközök által adott eredmények alapján az összes módszerről megállapítható, hogy nagyobb tanítási adatmennyiség mellett egyre kisebb hibával lesz képes megbecsülni a halál időpontját (3. ábra). Mind a MAE, MSE, mind pedig az R^2 (≈ 1) értékek alapján, a legjobbnak az SVR és az adaptív regressziós fa együttes alkalmazása bizonyul, mivel ez a módszer még tovább javít az SVR által kapott eredményen.

(a) SVR				(b) AdaBoost + SVR			
	MAE	MSE	R^2		MAE	MSE	R^2
C=10	0,2578	0,2746	0,9886	C=10	0,2177	0,1340	0,9944
C=20	0,2255	0,2252	0,9906	C=20	0,1875	0,0987	0,9959
C=50	0,1979	0,1828	0,9924	C=50	0,1820	0,1109	0,9954
C=100	0,1683	0,1290	0,9947	C=100	0,1606	0,0762	0,9969

2. táblázat. $C=50$ és $C=100$ paraméterekkel kapott SVR és AdaBoost + SVR eredmények ≈ 11000 esetszámmal.


A C paraméter jelenti a kompromisszumot a téves besorolási hibák minimalizálása és a döntési határ maximalizálása között. A 2. táblázat alapján megállapítható, hogy C értékének növelésével tovább javítható az elért eredmény.

A különböző kiválasztott módszerek eredményeit összehasonlítva elmondható, hogy a két legjobb eredményt az SVR és az AdaBoost+SVR adja, ahogy az 4. ábrán és az 3. táblázatban is látható, mivel ezen két módszer esetén van a legtöbb teszt eredmény 1σ -n belül.


3. táblázat. A különböző módszerek eredményei 1σ és 2σ esetén.

Név	1σ érték	2σ érték	1σ	2σ
Decision tree	-1,1751-1,0571	-2,2912-2,1732	2161 (80,36%)	2546 (94,68%)
Bagging	-0,64297-0,60864	-1,2688-1,2344	2004 (74,53%)	2506 (93,19%)
Random forests	-0,64995-0,59144	-1,2706-1,2121	2034 (75,64%)	2504 (93,12%)
Extra trees	-0,5316-0,51464	-1,0601-1,0395	2064 (76,76%)	2514 (93,49%)
SVR	-0,60545-0,54442	-1,1804-1,1194	2292 (85,24%)	2569 (95,54%)
AdaBoost + SVR	-0,3423-0,32924	-0,67807-0,66501	2076 (77,2%)	2552 (94,91%)


Összehasonlítva a Henssge nomogrammal, ahol mindkét hőmérsékleti tartomány esetén korrekciós faktorok alkalmazásával a pontosság $\pm 2,8$ óra elmondható, hogy a létrehozott modell alkalmas a tanult adathalmaz alapján kellő pontossággal megbecsülni a halál időpontját a korlátok figyelembevételével. A szintetikus modell jelenlegi korlátai a korrekciós faktorok darabszáma, fél óra pontossággal megadott tanító adatok és a testtömeg 50-100kg között.



(a)

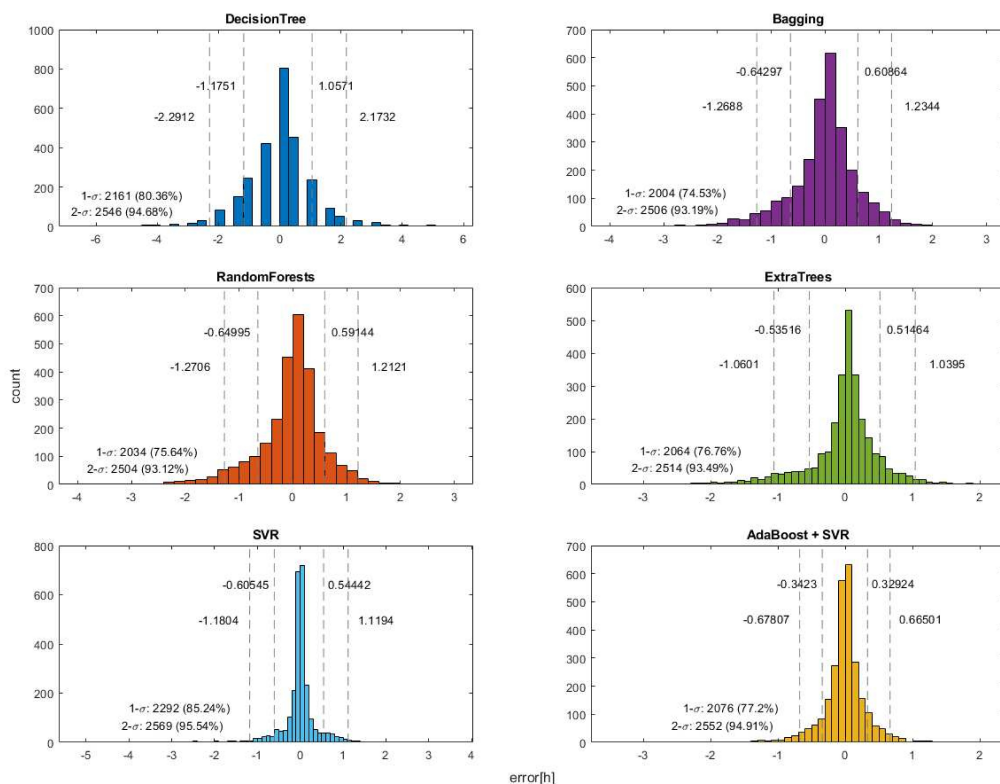


(b)



(c)

3. ábra. Szintetikus modell hibái



4. ábra. A különböző módszerek eredményei 1σ és 2σ esetén.

A 3. ábráról leolvasható, hogy a legtöbb választott matematikai eszköz már minimum 3000 tanító esetszámmal is alacsony hibával tudja a modell megbecsülni a halál időpontját a jelenlegi beállítások mellett. Mivel kevés adatra van szükség a tanításhoz, ezért akár geográfiai régiókban is alkalmazható (földrajzilag kisebb területi egységre vonatkoztatva) a modell. Könnyen adaptálható adott népességre, amelyek különböző antropometriai jellemzőkkel rendelkeznek vagy eltérő éghajlati övben élnek.

Összehasonlítás más eredményekkel

Neurális háló

Neurális hálózat alapú módszert dolgozott ki a PMI becslésére Zerdazi és társai [12], akik többrétegű előrecsatolt hálózatokat használtak, felügyelt tanulási móddal. Vizsgálatukhoz igazságügyi orvosszakértő által gyűjtött, 257 fős tanulási mintát használtak, hogy bizonyítsák az új technika előnyeit, mely pontosságát az átlagos négyzetes hibával illetve az átlagos abszolút hibával jellemezték és összehasonlították a Henssge formula által kapott eredménnyel. A méréseket mindig ugyanolyan körülmények között végezték: száraz, mozgás nélküli levegő és teljesen meztelen test.

A kapott eredményeket összehasonlították a Henssge féle módszerrel és ennek jellemzésére az átlagos négyzetes hibát használták, mely alapján elmondható, hogy a neurális hálózat sokkal pontosabb becslést ad a PMI-re (4. táblázat). Ezen eredménnyel hasonlítottam össze a szintetikus modellel kapott eredményeket.

Módszer neve	MSE	MAE
Henssge formula	20,83	3,52
Zerdazi-féle neurális hálózat	5,69	1,85
SVR	0,14	0,17
AdaBoost + SVR	0,12	0,17

4. táblázat. Henssge formula, a Zerdazi-féle neurális hálózat és a szintetikus modell MSE és MAE értékeinek összehasonlítása

Az összehasonlító vizsgálat következő változata azokra az esetekre korlátozódott, akik post mortem periódusa nem haladta meg a 7 órát. Az így kapott eredményeket az 5. táblázat foglalja össze. A Zerdazi-féle neurális hálózat és a szintetikus modell eredményeinek összehasonlíthatósága céljából újra tanítottam és teszteltem a modell azokkal a paraméterekkel, melyek alapján Zerdazi és társai az eredményeiket kapták. A szintetikus modell SVR és AdaBoost + SVR módszerrel becsült eredményeinek hibáját az 4-5. táblázatok tartalmazzák.

Módszer neve	MSE	MAE
Henssge formula	21,14	3,51
Zerdazi-féle neurális hálózat	1,21	0,86
SVR	0,08	0,18
AdaBoost + SVR	0,05	0,14

5. táblázat. Henssge formula, a Zerdazi-féle neurális hálózat és a szintetikus modell MSE és MAE értékeinek összehasonlítása 7 órát nem meghaladó PMI esetekre

Összességében megállapítható az 4-5. táblázatok MAE és MSE értékei alapján, hogy a szintetikus modell egy nagyságrenddel kisebb hibával becsült, mint a Zerdazi-féle neurális hálózat.

Valós tesztadatok alapján kapott eredmények


A szintetikus modell tesztelését valós adatokon is elvégeztem. Teszt adatnak Muggenthaler és társai által publikált adatbázisból választottam véletlenszerűen eseteket, figyelve arra, hogy a jelenleg betanított modell korlátait is ellenőrizni tudjam [13].

Az eredmények kiértékelése alapján elmondható, hogy a 20 választott eset közül 5 esetén nagyobb az eltérés a grafikonról leolvasott értéknél, mint 150 perc. A publikált táblázat alapján megállapítható, hogy az eltérésnek több oka is lehet:

- minden esetben volt késleltetés a halál bekövetkezése és a mérés megkezdése között (átlagosan 130 perc),
- a kiinduló testhőmérsékletek is eltérést mutatnak a Henssge módszer definiált kiindulási hőmérsékletéhez képest, ami $37,2^{\circ}\text{C}$,
- a szintetikus modell 50–110 kg közötti tömegeken tanult, mivel több réteg ruha esetén ezen értékek alatt és felett módosítani kell a korrekciós faktorok értékén,
- vannak olyan betegségek, például a szeptikus esetek, amikor a testhőmérséklet alacsonyabb vagy akár magasabb is lehet, mint normál esetben,
- a publikált adatokban nem volt korrekciós faktor meghatározva, így azokat a ruházat alapján választottam ki,
- a holttestek fém asztalon feküdtek a hűtőkamrában,
- a publikált hűlési görbék esetén a késleltetett mérés megkezdése miatt szinte minden esetben hiányzik a plató fázis és némelyik nem az elvárt szigmoid, hanem inkább lineáris hűlési folyamatot tükrözi.

A valós eseteket a két legkisebb hibával becslő módszerrel ellenőriztem, így az Ada-Boost + SVR, illetve az SVR módszerre vonatkozóan értékeltem ki részletesebben az eredményeket, de elmondható, hogy a többi regressziós módszer esetén sem volt számottevően rosszabb eredmény.


A valós esetek alapján kapott eredmények alapján megállapítható, hogy a szintetikus modell a tanulási adatok korlátain belül alkalmas a PMI becslésére, a nem szokványos esetekben pedig fenntartásokkal kell kezelni a kapott eredményt és szükség esetén más hullajelenségeket is figyelembe venni, az PMI pontosabb meghatározásához.



5. ábra. A hűlési grafikonról leolvasott értékektől való eltérés AdaBoost + SVR esetén

No.	$ SM_{2925} - T_g [\text{perc}]$	$ SM_{3909} - T_g [\text{perc}]$	$ SM_{10755} - T_g [\text{perc}]$
3	57	38	44
8	13	21	1
10	148	147	146
13	38	32	24
17	411	397	351
19	40	11	52
23	398	370	307
29	43	42	38
34	261	318	83
44	50	52	57
46	35	2	26
52	27	32	45
61	37	51	30
69	138	161	173
72	278	279	282
75	74	65	61
76	358	366	363
80	143	118	155
83	118	158	106
84	129	144	109

6. táblázat. A hűlési grafikonról leolvasott értékektől való eltérés AdaBoost + SVR esetén



6. ábra. A hűlési grafikonról leolvasott értékektől való eltérés SVR esetén

No.	$ SM_{2925} - T_g [\text{perc}]$	$ SM_{3909} - T_g [\text{perc}]$	$ SM_{10755} - T_g [\text{perc}]$
3	52	37	39
8	4	4	5
10	146	147	150
13	40	27	19
17	455	358	299
19	171	150	192
23	330	229	150
29	41	41	41
34	288	302	191
44	52	47	55
46	73	46	107
52	29	29	24
61	35	35	54
69	133	152	158
72	263	285	269
75	57	60	59
76	349	362	369
80	133	172	164
83	214	97	95
84	99	93	123

7. táblázat. A hűlési grafikonról leolvasott értékektől való eltérés SVR esetén

Konklúziók és kitekintés

A PhD munkám során a cél az volt, hogy feltárjam a PMI becslést befolyásoló tényezőket és egy olyan rugalmas matematikai modell létrehozásához találjak megfelelő eszközöket, mely kisebb hibával képes becsülni, mint a Henssge nomogram.

Kutatásom során gépi tanulási eszközök használatával létrehoztam egy szintetikus modellt, mely képes magában foglalni a PMI-t befolyásoló tényezőket a tanítási adattal, vagyis nem követeli meg a Henssge formula ismeretét és használatát korrekciós faktorokkal, és nem tartalmaz empirikus változókat. A modell alapját generált adatok képezték, melyek hasonlítanak a valósághoz, ennek részletesebb taglalására a későbbiekben kerül sor. A cél egy rugalmas, könnyen adaptálható matematikai módszer létrehozása volt. Mivel a halál időintervallumának becslése matematikailag felfogató ügy, mint egy lineáris regressziós probléma megoldása, így a rendelkezésre álló gépi tanulási eszközöket ez alapján választottam ki. Döntésem egy felügyelt tanulási módszerre esett, az SVM-re, mely egy speciális neurális hálózatnak tekinthető, mind lineáris, mind klasszifikációs problémák megoldására is alkalmas. A döntési függvényhez különböző kernelfüggvények választhatóak, melyek közül a szintetikus modell az RBF-et használja arra, hogy a megoldandó feladatot leíró adatokat a kernel térbe transzformálja nemlineáris transzformációk segítségével.

Munkám során a cél az volt, hogy megmutassam, hogy létezik olyan regressziós módszer, mely jobb eredményt ad, mint a Henssge formula. A vizsgált eszközök: SVR RBF kernellel, regressziós fa, random forests, extrém módon randomizált fák, zsákolás módszerével módosított fa, adaptív boostinggal javított SVR. A kérdés, hogy *melyik módszer adja a legjobb becslést és mekkora a becslés várható hibája?* A tanulmány eredményei alapján kijelenthető, hogy a gépi tanulási eszközökkel, például döntési fák vagy SVM alkalmazásával becsült PMI jobb eredményeket adott, mint a Henssge formula. A létrehozott szintetikus modellt több különböző darabszámú tanító adattal tanítottam és minden esetben ugyanannyi (500) darabszámú tesztadattal teszteltem. A tanításhoz használt adatok darabszámát 968 darabtól kezdve megközelítőleg ezersével emeltem 11708 esetig. Minden különböző darabszámú tanítás esetén minden kiválasztott regressziós módszerrel becsültem PMI eredményeket a tesztadatokhoz. A módszerek hibáit (MAE, MSE, R^2) és paraméterezését rögzítettem. A szintetikus modell hibáját Zerdazi [12] neurális hálózatának eredményeivel hasonlítottam össze, ezért a hibát két módon vizsgáltam: MAE, MSE. A Zerdazi-féle neurális hálózat eredményei: $MSE = 5.69$, $MAE = 1.85$. Ezzel összehasonlítva a szintetikus modell által adott eredmények hibáit, elmondható, hogy pontosabb becslést ad a PMI-re. A vizsgálatok

során azt az eredményt kaptam, hogy a PMI becslésére a legjobb eredményt, az RBF kernellel rendelkező SVM és az AdaBoost együttes használata adta. A modell hibái SVR módszer esetén: $MSE = 0.14$, $MAE = 1.17$; AdaBoost+SVR módszer esetén pedig: $MSE = 0.12$, $MAE = 1.17$ értékeket vettek fel. A modell által kapott átlagos hiba a konfidencia intervallumon belül 0.17 ± 0.34 óra, a modell jelenlegi korlátaival.

Fontos megválaszolendő kérdés volt az alkalmazhatóság szempontjából az, hogy *mekkora mennyiségű tesztadatra van szükség* a szintetikus modell tanításához, hogy kellő pontossággal tudjon PMI-t becsülni. A létrehozott szintetikus modell könnyen adaptálható különböző jellemzőkkel rendelkező vagy eltérő éghajlati övezetekben élő populációkhoz, mivel nem egy fix, empirikus úton létrehozott matematikai összefüggésből áll, hanem a tanult adatok alapján képes becsülni, ezzel figyelembevéve az adott területre, népcsoportra jellemző specialitásokat, melyeket a tanító adatok tartalmaznak. A szintetikus modell előnye továbbá az, hogy kevés darabszámú tanító adat is elegendő a PMI becsléshez, ez a modell jelenlegi felépítése és a jellemzők darabszáma mellett 3000 adat.

A célkitűzésben feltettem azt a kérdést, hogy: *Mely esetekben nem alkalmazható a modell?* A modell a Henssge formula segítségével generált adatokon tanul. Ez korlátokat szab az alkalmazhatóságára, de ez a korlát csak az adatok jellege miatt jelenik meg, maga a módszer az univerzális. A tanulmány célja az volt, hogy megmutassam az adott körülmények között a modell ténylegesen alkalmazható. A módszer jellege olyan, hogy ha valós adatokon tanítjuk, akkor általánosabb esetben is használható lesz. Ezt az állítást arra alapozom, hogy a jelenlegi, korlátozott adatokon alapuló modell megfelelően pontosan becsült, amikor empirikus adatokkal vettem össze. Környezeti hőmérséklet szempontjából az alkalmazhatóság -10 – 35°C közötti tartományt jelent, alatta és felette nem tud eredményt adni. Abban az esetben is hibás eredményt kapunk, ha a rektális hőmérséklet alacsonyabb, mint a környezeti hőmérséklet. Ilyen a gyakorlatban csak akkor fordulhat elő, ha a testet hűtötték, majd melegebb helyre vitték, illetve, ha a környezeti hőmérséklet tartósan alacsony volt, majd emelkedni kezdett, de a test még nem vette át a környezeti hőmérsékletet. A Henssge nomogramok alapján megállapítható, hogy az alkalmazhatóságnak időbeli korlátja is van (jelenleg 18 óra), mely a környezeti hőmérséklettől függ: 23°C felett maximum 30 óra, 23°C alatt akár 70 óra is lehet, de ekkor már nagyon magas hibával ad eredményt. Korrekciós faktor használatával ez a bizonytalanság akár ± 7 óra is lehet, míg ruha nélküli test esetén $\pm 4,5$ óra.

A szintetikus modell tesztelése során találkoztam olyan esetekkel is, melyek ugyan nem felelnek meg az előbb felsorolt kivételeknek, mégis magasabb hibával becsül mind a szintetikus modell, mind pedig a Henssge formula. Kiemelve egy esetet, amikor biztosan hibás eredmény ad a modell, ha a holttesten pelenka van. Mivel végbél hőmérsékletet vesz figyelembe a Henssge formula, így a szintetikus modell is, ezért a teljes test ruházatára vonatkozó korrekciós faktor nem alkalmas arra, hogy a pelenka szigetelő hatását jellemezze, így a matematikai modellek sokkal rövidebb időt fognak adni eredményül. Ezek tipikusan olyan esetek, melyek nem felelnek meg egy olyan sablonnak, melyre egy empirikus formulát alkalmazni lehet, vagyis hiába becsül kis hibával a matematikai modell, a kapott eredményt mindig fenntartásokkal kell kezelni és adott

esetben felül bírálni, vagy a korai hullajelenségekkel együttesen értelmezni.

A szintetikus modell jelenlegi korlátai

1. Nem kezeli a módosított korrekciós faktorokat.
2. Mivel az adatok generálásához a Henssge formulát használtam, így annak lehetséges tévedéseit és korlátait is megtanulta a modell.
3. Nem változtathatóak a kód módosítása nélkül az időre, a környezeti hőmérsékletre és a testtömegre vonatkozó intervallumok:
 - (a) idő: 1–18 óra, 0,5 órás lépésközzel,
 - (b) környezeti hőmérséklet: $-10-35^{\circ}\text{C}$, 0,5 $^{\circ}\text{C}$ lépésközzel,
 - (c) testtömeg: 50–100kg, 0,5 kg-os pontossággal.
4. Tanító és tesztadatok meghatározott felépítésű fájlból történő beolvasása.
5. Parancssorból használható a tanítást és a becslést végző kód, a megfelelő kapcsolók alkalmazásával.

A szintetikus modell továbbfejlesztési lehetőségei

1. A módosított korrekciós faktorokat automatikus kezelése.
2. Kód felkészítése a tanító és a tesztadatok meghatározott felépítésű fájlból történő beolvasására.
3. Választható lehetőségként meghagyni az adatok generálását tetszőlegesen megadható idő, környezeti hőmérséklet és testtömeg intervallumokra, tetszőleges lépésközzel.
4. Felhasználóbarát grafikus felület elkészítése a tanításhoz.
5. Felhasználóbarát grafikus felület elkészítése a becsléshez szükséges adatok megadásához.
6. A távlati cél, a modell olyan platformon történő publikálása, mely lehetővé teszi a mindennapi gyakorlatban történő tesztelését is.

Új tudományos eredmények összefoglalása

1. Létrehoztam egy szintetikus adatokon alapuló, gépi tanulási eszközöket használó modellt a postmortem időintervallum (PMI) becslésére. Könnyen adaptálható különböző jellemzőkkel rendelkező, vagy eltérő éghajlati övezetekben élő populációkhoz.
2. Tanulmányoztam különböző gépi tanulási eszközök hatékonyságát. A döntési fákkal és SVM-el működő modell becslési eredményei pontosabbak, mint a Henssge formula vagy a neurális hálózatot használó módszer.
3. Készítettem egy szabadon hozzáférhető python szkriptet, mely megvalósította a modellt és alkalmas a PMI becslésre. A modell folyamatosan fejleszthető, újra tanítható, alacsony képzési adatszámmal is kis hibaarányal becsl.
4. Összehasonlítottam a létrehozott modellt más, gépi tanuláson alapuló módszerrel. A szintetikus modell pontosabb eredményeket adott, mint a neurális hálózaton alapuló módszer.
5. Összehasonlítottam a létrehozott modellt empirikus adatokkal. A szintetikus modellel egy kényelmesebb, modernebb és pontosabb megoldást adtam a PMI becslésre, mint a Henssge nomogram.

Köszönetnyilvánítás

Szeretném köszönetemet kifejezni témavezetőimnek, dr. Frigyik B. Andrásnak és dr. Kozma Zsoltnak, hogy a PhD munkám során végig vezettétek, támogattátok és szakmai tudásotokkal segítettétek munkámat az évek során.

Köszönöm prof. dr. Nyitrai Miklósnak, hogy kezdetben témavezetőmként támogatott és lehetővé tette, hogy csatlakozzak a Funkcionális fehérjedinamika vizsgálata biofizikai módszerekkel programba.

Köszönetemet szeretném kifejezni dr. Simon Gábornak, az Igazságügyi Orvostani Intézet vezetőjének, hogy a kutatásom az intézetben végezhettem és kutatómunkám során mindenben számíthattam támogatására.

Köszönettel tartozom dr. Tóth Dénesnek, a munkámban nyújtott segítségért és a rengeteg beszélgetésért, ami bővítette tudásomat egy számomra elsöre idegen területen, az igazságügyi orvostanban és lendületet adott a kutatásomnak.

Köszönettel tartozom családomnak és szeretteimnek, a támogatásotokért és türelmetekért, hogy végig kísértetek ezen az úton.

Irodalomjegyzék

- [1] H. Rainy, „On the cooling of dead bodies as indicating the length of time since death”, *The Glasgow Medical Journal*, 1. évf., 323–330. old., 1868.
- [2] F. H. T. K. Marshall, „Estimating the time since death - the rectal cooling after death and its mathematical representation”, *Journal of Forensic Sciences*, 7. évf., 56–81. old., 1962.
- [3] T. K. Marshall, „The use of the cooling formula in the study of post mortem body cooling”, *Journal of Forensic Sciences*, 7. évf., 189–210. old., 1962.
- [4] T. K. Marshall, „The use of body temperature in estimating the time of death”, *Journal of Forensic Sciences*, 7. évf., 211–221. old., 1962.
- [5] *Sigmoidal shape of the cooling curve*. cím: https://www.researchgate.net/figure/Sigmoidal-shape-of-the-cooling-curve-which-is-best-described-by-Marshall-and-Hoares_fig5_303796826.
- [6] C. Henssge, „Todeszeitschätzungen durch die mathematische Beschreibung der rektalen Leichenabkühlung unter verschiedenen Abkühlungsbedingungen”, *Zeitschrift für Rechtsmedizin*, 87. évf., 147–178. old., 1981. DOI: 10.1007/BF00204763.
- [7] C. Henßge, „Die Präzision von Todeszeitschätzungen durch die mathematische Beschreibung der rektalen Leichenabkühlung”, *Zeitschrift für Rechtsmedizin*, 83. évf., 49–67. old., 1979. DOI: 10.1007/BF00201311.
- [8] C. Henssge, „Death time estimation in case work. I. The rectal temperature time of death nomogram”, *Forensic science international*, 38. évf., 209–236. old., 1988. DOI: 10.1016/0379-0738(88)90168-5.
- [9] C. Henssge, B. Madea és E. Gallenkemper, „Death time estimation in case work. II. Integration of different methods”, *Forensic Science International*, 39. évf., 1. sz., 77–87. old., 1988. DOI: 10.1016/0379-0738(88)90120-X.
- [10] C. Henssge, „Rectal temperature time of death nomogram: Dependence of corrective factors on the body weight under stronger thermic insulation conditions”, *Forensic Science International*, 54. évf., 1. sz., 51–66. old., 1992. DOI: 10.1016/0379-0738(92)90080-G.
- [11] C. Henssge, E. Beckmann, F. Wischhusen és B. Brinkmann, „Todeszeitbestimmung durch Messung der zentralen Hirntemperatur”, *Zeitschrift für Rechtsmedizin. Journal of legal medicine*, 93. évf., 1. sz., 1–22. old., 1984. DOI: 10.1007/bf00202979.

- [12] D. Zerdazi, A. Chibat és F. L. Rahmani, „Estimation of Postmortem Period by Means of Artificial Neural Networks”, *Electronic Journal of Applied Statistical Analysis*, 9. évf., 2. sz., 2016.
- [13] H. Muggenthaler, I. Sinicina, M. Hubig és G. Mall, „Database of post-mortem rectal cooling cases under strictly controlled conditions: a useful tool in death time estimation”, *Int J Legal Med*, 126. évf., 1. sz., 79–87. old., 2011. máj.

Az értekezés alapjául szolgáló közlemény

Dani, Livia Mária and Tóth, Dénes and Frigyik, Andrew B. and Kozma, Zsolt
Beyond Henssge's Formula: Using Regression Trees and a Support Vector Machine for Time of Death Estimation in Forensic Medicine.

Diagnostics 13(7):1260. (2023)

<https://doi.org/10.3390/diagnostics13071260>

Impakt faktor: 3.6

Az értekezéshez kapcsolódó előadás

Dani Livia Mária, Frigyik Béla András, Tóth Dénes, Nyitrai Miklós, Kozma Zsolt
A halál matematikája, avagy az exponenciálisok csapdájában
MIOT 2018 Pécs, A Magyar Igazságügyi Orvosok Társasága XVI. Nemzetközi Konferenciája