Translated from English to Slovak - www.onlinedoctranslator.com

International Journal of Medical Toxicology & Forensic Medicine

Január 2026, ročník 16, E50757

Výskumná práca

Prieskumná štúdia využívajúca umelú neurónovú sieť na predpovedanie únavy z používania mobilného telefónu: Prieskum populácie v Alžírsku

Souad Boumaiza[1,2]*, **Saddek Bouharati**[3], **Abdelouahab Bouzidi**[1]

1. *Katedra biochémie, Fakulta prírodných vied a biológie, Univerzita Ferhata Abbasa Setif 1, Setif 19000, Alžírsko.*

2. *Katedra biologických vied, Fakulta prírodných vied, vied o Zemi a vesmíre, Univerzita Mohameda El Bachira El Ibrahimiho, Bordj Bou Arréridj, Alžírsko.*

3. *Laboratórium inteligentných systémov, Technologická fakulta, Univerzita Ferhata Abbása Setif 1, Setif, Alžírsko.*

Citation Boumaiza S, Bouharati S, Bouzidi A. Prieskumná štúdia využívajúca umelú neurónovú sieť na predpovedanie únavy z mobilného telefónu Použitie: Prieskum populácie v Alžírsku. Medzinárodný časopis lekárskej toxikológie a súdneho lekárstva 2026; 16:E50757.

https://doi.org/10.22037/ijmtfm.v16.50757

Informácie o článku:

Prijaté: 1. novembra 2025

Prvá revízia: 14. novembra 2025

Prijaté: 21. novembra 2025

Publikované: 1. januára 2026

Kľúčové slová:

Únava, Mobilný telefón, Rádiofrekvencia, umelé neurónové siete (ANN), MATLAB

ABSTRAKT

Pozadie: Mobilné telefóny sa hojne používajú, čo vyvoláva otázky o možných zdravotných účinkoch rádiofrekvenčných elektromagnetických polí, ktoré vyžarujú. V tejto súvislosti sa často uvádza únava, ale je ovplyvnená viacerými interagujúcimi faktormi, ktoré je ťažké modelovať klasickými štatistickými metódami. Umelé neurónové siete (ANN) môžu pomôcť preskúmať tieto zložité vzťahy.

Metódy: Na odhad únavy spojenej s používaním mobilného telefónu bol vyvinutý model ANN. Údaje boli zozbierané prostredníctvom pološtruktúrovaného dotazníka, ktorý vyplnilo 478 alžírskych účastníkov. Prieskum zaznamenával sociodemografické údaje a vzorce používania mobilných telefónov. Sieť mala architektúru 5-10-1 a jej výkon bol hodnotený pomocou strednej štvorcovej chyby (MSE) a koeficientu determinácie (R^2). Bolo vytvorené jednoduché rozhranie MATLAB, ktoré umožňuje vstup používateľa a zobrazuje výstupy modelu s farebne kódovaným indikátorom.

Výsledky: ANN dosiahla MSE 0,5993, čo naznačuje, že reprodukovala niektoré všeobecné vzorce v údajoch. Koeficient determinácie bol však nízky (R^2 = 0,0338), čo ukazuje, že bola vysvetlená len malá časť variability v skóre únavy a že individuálne predpovede boli nepresné.

Záver: Táto prieskumná štúdia naznačuje, že modely založené na umelých neuronálnych sieťach (ANN) sú uskutočniteľné na analýzu únavy spojenej s používaním mobilných telefónov, ale zistenia by sa mali považovať za predbežné a podliehajú určitým obmedzeniam. Predtým, ako sa takéto nástroje budú môcť použiť na spoľahlivé hodnotenie rizík alebo usmernenia v oblasti verejného zdravia, budú potrebné väčšie, rozmanitejšie vzorky a bohatšie, najlepšie objektívne merania expozície a zdravia.

*** Zodpovedajúci autor:**

Souad Boumaiza, PhD

Katedra biochémie, Fakulta prírodných vied a biológie, Univerzita Ferhata Abbasa Setif 1, Setif 19000, Alžírsko. E-mail: *souad.boumaiza.dz@gmail.com*

Autorské práva © 2026 Autor(i);

Toto je článok s otvoreným prístupom distribuovaný podľa podmienok licencie Creative Commons Attribution License (CC-By-NC:https://creativecommons.org/licenses/by-nc/4.0/legalcode.en), ktorá povoľuje použitie, distribúciu a reprodukciu v akomkoľvek médiu za predpokladu, že pôvodné dielo je riadne citované a nepoužíva sa na komerčné účely.

International Journal of
Medical Toxicology & Forensic Medicine

Úvod

Používanie mobilných telefónov sa celosvetovo zvýšilo na úroveň, aká doteraz nebola zaznamenaná. Keďže sa tieto zariadenia stali súčasťou každodenného života, narastajú aj otázky o možných vplyvoch vystavenia rádiofrekvenčným elektromagnetickým poliam na verejné zdravie. (RF-EMF) [1, 2]. Rozšírenie zdrojov vyžarujúcich RF, ako sú mobilné telefóny, základňové stanice a prístupové body Wi-Fi, zmenilo spôsob a frekvenciu vystavenia ľudí. Expozícia na úrovni populácie však zostáva nedostatočne popísaná a relatívny príspevok každého zdroja zostáva neistý [1]. Medzinárodná agentúra pre výskum rakoviny (IARC) klasifikovala RF-EMF ako „skupinu 2B – potenciálne karcinogénne pre ľudí“ [3]. Experimentálne štúdie naznačujú, že RF môžu ovplyvňovať bunkové procesy, mozgovú aktivitu a imunitné reakcie a deti môžu byť obzvlášť zraniteľné [2].

Systematické preskúmania hlavných zdravotníckych agentúr nepreukázali jasnú kauzálnu súvislosť medzi každodenným vystavením sa rádiofrekvenčným elektromagnetickým poliam a nepriaznivými zdravotnými následkami. Takéto vystavenie sa však spája so subjektívne hlásenými príznakmi vrátane únavy, zhoršenia pamäti, hypertenzie, neplodnosti, porúch spánku a niektorých nádorov [2, 4-7]. Únava je jednou z najčastejšie hlásených sťažností, najmä u intenzívnych používateľov mobilných telefónov [8, 9].

Tradične, štúdie vyšetrovanie ten Vzťah medzi expozíciou mobilným telefónom a zdravotnými následkami sa spoliehal na štatistické modely, ako je lineárna alebo logistická regresia. Tieto prístupy sa bežne používajú na posúdenie súvislostí medzi expozičnými premennými (napr. denná dĺžka telefonátu) a subjektívne hlásenými výsledkami (napr. únava). Únava súvisiaca s používaním bezdrôtových technológií však vyplýva zo zložitej, nelineárnej a multifaktoriálnej interakcie sociodemografických a expozičných faktorov, ktoré klasické štatistické modely nemusia dostatočne zachytiť [9, 10]. Toto spoliehanie sa na lineárne modely predstavuje hlavnú medzeru vo vedomostiach, pretože zostáva nejasné, či by flexibilnejšie, nelineárne prístupy mohli lepšie zachytiť tieto zložité vzťahy. Naproti tomu umelé neurónové siete (ANN) ponúkajú flexibilnejší prístup, pretože sa dokážu učiť skryté, nelineárne vzťahy priamo z údajov [11-16]. Inšpirované fungovaním ľudského mozgu, ANN už preukázali svoju užitočnosť v biomedicínskych aplikáciách, najmä pri predikcii chorôb [13, 16].

Na vyriešenie tejto medzery sa v predloženej štúdii vyvíja model umelej neuronálnej siete (ANN) na predpovedanie únavy súvisiacej s používaním mobilného telefónu.

-

používanie mobilných telefónov v alžírskej populácii. Model je založený na piatich vstupných premenných: vek, pohlavie, dĺžka vlastníctva telefónu, dĺžka denného používania telefónu a vzdialenosť telefónu od tela počas spánku. Pomocou týchto premenných ANN odhaduje úroveň vnímanej únavy a pomáha identifikovať, ktoré faktory najsilnejšie prispievajú k jej variácii. Takéto informácie môžu podporiť cielené stratégie prevencie a lepšie usmernenie pre používanie mobilných telefónov v každodennom živote. Podľa našich najlepších vedomostí žiadna predchádzajúca štúdia nepoužila ANN na modelovanie únavy spojenej s používaním mobilného telefónu.

Materiály a metódy

Zber údajov

Táto štúdia sa uskutočnila v Alžírsku s účastníkmi vystavenými rádiofrekvenčným emisiám z mobilných telefónov. Použil sa pološtruktúrovaný dotazník, ktorý bol zaslaný náhodne vybranej vzorke. Vzorka zahŕňala ľudí rôzneho veku a oboch pohlaví, aby sa zabezpečilo široké sociodemografické zastúpenie.

Pred účasťou boli všetci účastníci informovaní o cieľoch štúdie a poskytli písomný súhlas. Výskum sa tiež riadil etickými zásadami uvedenými v Helsinskej deklarácii. Všetky odpovede boli anonymizované, aby sa chránila dôvernosť účastníkov, a údaje boli bezpečne uložené [17]. Prieskumu sa zúčastnilo celkovo 478 osôb zo 48 wilayas (provincií) (obrázok 1).

Dotazník použitý v tejto štúdii bol vyvinutý na základe prehľadu literatúry o potenciálnych účinkoch vystavenia rádiofrekvenčnému žiareniu. Najprv bol pilotne testovaný na vzorke 20 jednotlivcov, aby sa posúdila jasnosť otázok, relevantnosť formulácie a primeranosť možností odpovede. Následne boli vyhodnotené psychometrické vlastnosti nástroja. Získaný Cronbachov alfa koeficient bol 0,819, čo naznačuje dobrú vnútornú konzistenciu medzi položkami a spoľahlivosť považovanú za uspokojivú na výskumné účely. Na tomto základe bol index vnútornej validity 0,905, čo naznačuje vysoký stupeň vnútornej validity a umožňuje primeranú dôveru vo výsledky získané z tohto meracieho nástroja.

Pre model neurónovej siete boli vstupnými premennými: vek (v rokoch), pohlavie (muž alebo žena), počet rokov vlastníctva mobilného telefónu (< 1 rok; 2–5 rokov; 6–10 rokov; > 10 rokov), priemerná denná dĺžka hovoru (< 1 hodina; 1–2 hodiny; 3–4 hodiny; 5–8 hodín; > 8 hodín) a blízkosť mobilného telefónu počas spánku (pod vankúšom; 0,1–0,5 m; 0,5–1 m; > 1 m).

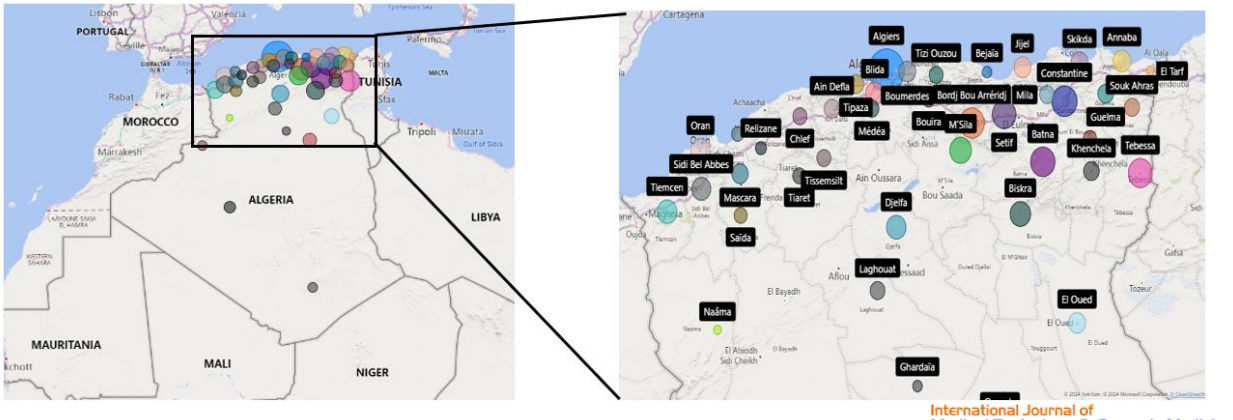

Obrázok 1. Geografické rozloženie účastníkov alžírskeho prieskumu (n = 478). Veľkosť každej farebnej bodky je úmerná počtu účastníkov v danej oblasti.

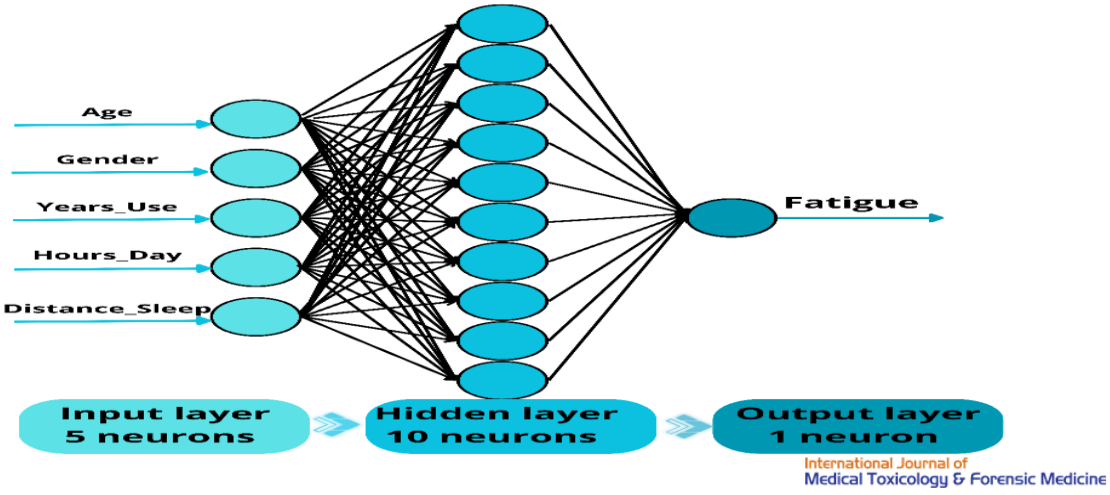

Obrázok 2. Schematické znázornenie navrhovaného modelu ANN.

Zatiaľ čo výstupnou premennou bol stupeň subjektívne hlásenej únavy, získaný zo sekcie dotazníka venovanej zdravotným symptómom (obrázok 2), frekvencia únavy bola hodnotená pomocou päťstupňovej Likertovej škály (nikdy, zriedkavo, niekedy, pri používaní mobilného telefónu a často).

Kódovanie dát a model ANN

Aby bolo možné spracovať ANN, všetky vstupné a výstupné premenné boli prevedené na číselné kódy. Pre pohlavie bola mužským účastníkom priradená hodnota 1 a ženským účastníčkam 2. Pre únavu bolo kódovanie nasledovné: 1 = nikdy, 2 = zriedkavo, 3 = niekedy, 4 = pri používaní mobilného telefónu a 5 = často. Ostatné kategorické premenné boli kódované podobne a vzorka súboru údajov bola použitá na trénovanie a testovanie modelu.

Navrhovaná umelá neuronálna sieť (ANN) je viacvrstvová dopredná sieť s piatimi vstupnými neurónmi, jednou skrytou vrstvou zloženou z 10 neurónov a jedným výstupným neurónom.

Tabuľka 1. Zhrnutie súboru údajov.

Pracovný priestor	
Meno	**Hodnota**
údaje	478×6 dvojité
hlavičky	1×6 buniek
skrytá_vrstva	10
mse	0,5993
sieť	Sieť 1×1
predpokladaný_výstup	1×143 dvojitý
r2	0,0338
surový	479 × 6 buniek
testovacie_údaje	143×6 dvojité
dáta_vlaku	335×6 dvojité
vlakový pomer	0,7000
vzorka_vlaku	335

International Journal of
Medical Toxicology & Forensic Medicine

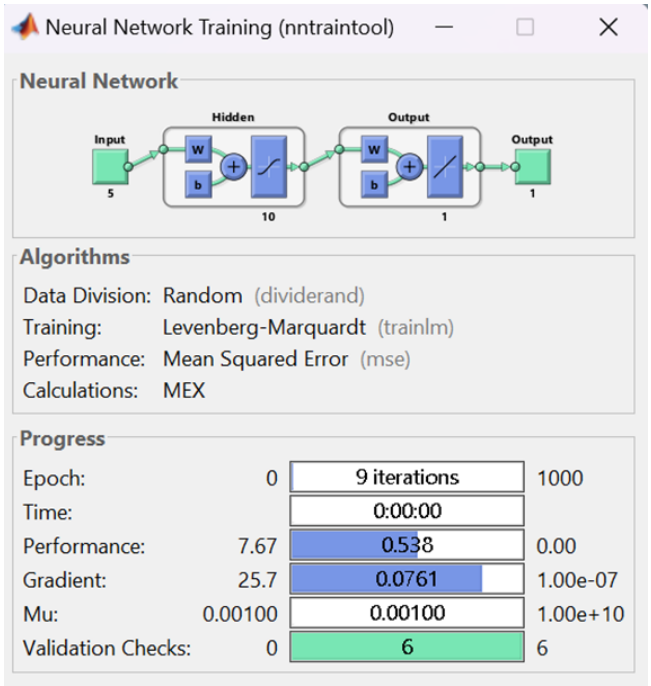

International Journal of Medical Toxicology & Forensic Medicine

Obrázok 3. Architektúra neurónovej siete a výkonnosť tréningu.

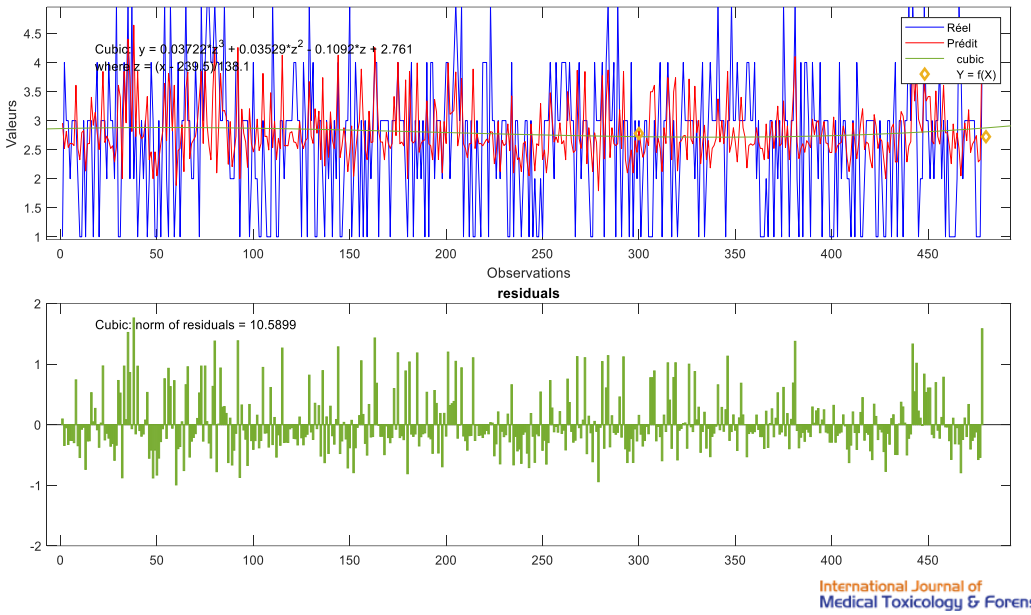

International Journal of Medical Toxicology & Forensic Medicine

Obrázok 4. Porovnanie skutočnej a predpokladanej úrovne únavy pomocou kubickej regresnej fitu a analýzy rezíduí.

zodpovedajúca predpokladanej úrovni únavy (topológia 5–10–1) (obrázok 2). Táto architektúra bola vybraná po predbežných skúškach, v ktorých bolo niekoľko kandidátskych topológií trénovaných s použitím rovnakého rozdelenia trénovanie/validácia/testovanie a algoritmu Levenberg-Marquardt. Výber modelu sa riadil strednou štvorcovou chybou validácie a koreláciou medzi pozorovanou a predpokladanou únavou.

Ten/Tá/To Levenberg–Marquardt spätné šírenie Bol zvolený algoritmus. Tento algoritmus je špeciálne navrhnutý pre nelineárne úlohy najmenších štvorcov a je známy tým, že poskytuje veľmi rýchlu konvergenciu pre malé až stredne veľké siete. Výkon modelu bol hodnotený hlavne pomocou strednej štvorcovej chyby (MSE). Ako je znázornené na obrázku 3, sieť bola

-

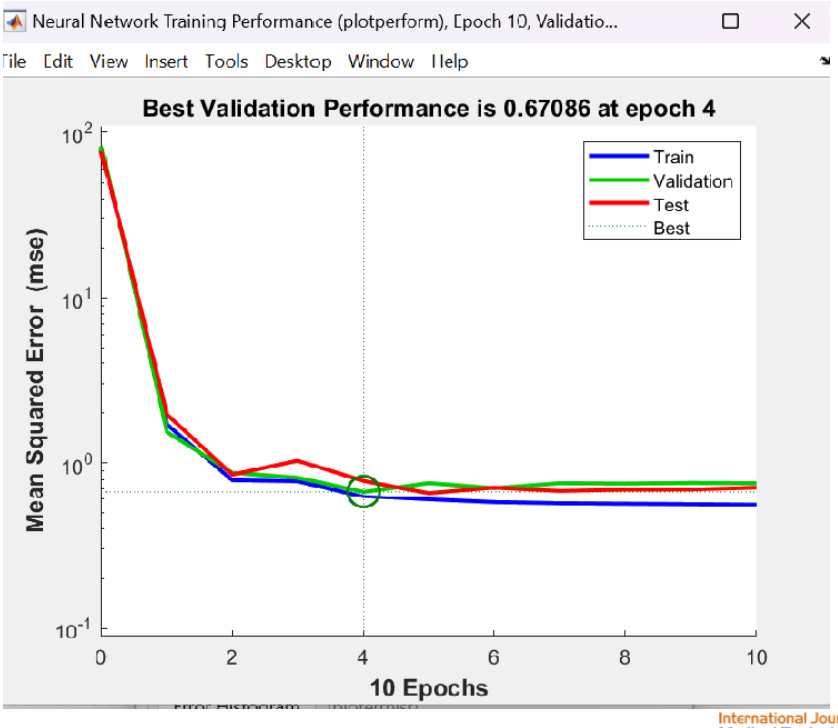

International Journal of
Medical Toxicology & Forensic Medicine

Obrázok 5. Trénovanie, validácia a testovanie výkonu modelu ANN.

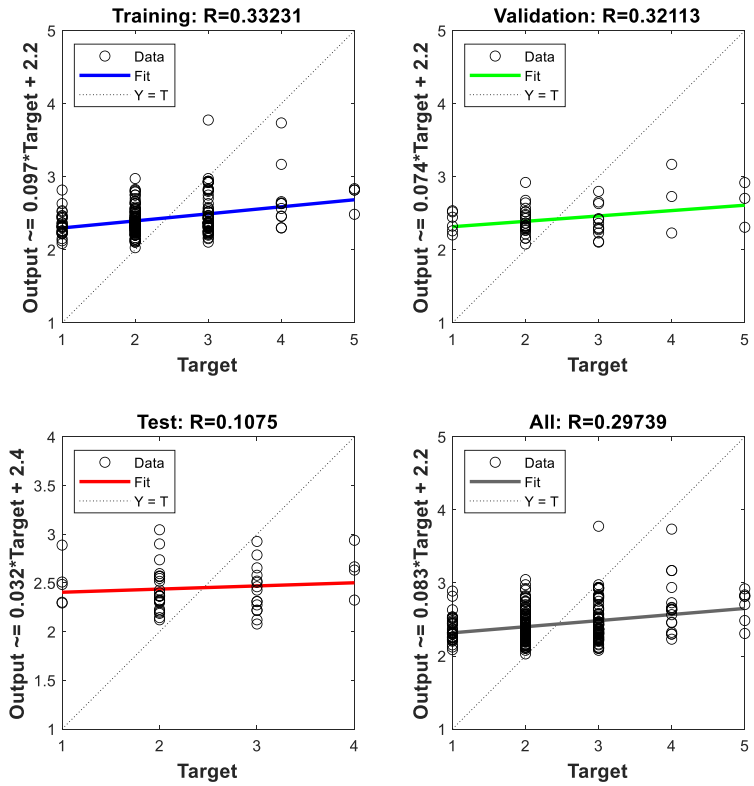

International Journal of
Medical Toxicology & Forensic Medicine

Obrázok 6. Regresné grafy medzi cieľovými a predpokladanými hodnotami únavy pre tréningové, validačné, testovacie a celkové súbory údajov.

trénované až 1 000 iterácií. Trénovanie sa však automaticky zastavilo už po deviatich iteráciách, pretože počas šiestich po sebe nasledujúcich validačných kontrol sa nepozorovalo žiadne ďalšie zlepšenie. Tento postup včasného zastavenia pomohol obmedziť preplnenie.

Optimalizačný proces je zhrnutý v tabuľke 1, ktorá ukazuje, že bolo spracovaných celkovo 478 pozorovaní so šiestimi premennými. Z nich bolo 335 vzoriek (70 %) použitých na trénovanie a 143 vzoriek (30 %) bolo rezervovaných na testovanie. Trénovaný model dosiahol

stredná štvorcová chyba (MSE) 0,5993 a nízky koeficient determinácie (R^2 = 0,0338).

To naznačuje, že hoci sieť v údajoch zistila určité vzory, väčšina variability v skóre únavy zostala nevysvetlená.

Na vizualizáciu výkonu modelu (obrázok 4) boli pozorované skóre únavy (modrá) vynesené do grafu vedľa predpovedí ANN (červená). K predpovedaným hodnotám (oranžová čiara) bola následne prispôsobená kubická regresná krivka, ktorá je opísaná rovnicou: y = 0,03722 z_3+ 0,03529 z_2− 0,1092 z + 2,761 (kde: z = (x−239,5)/138,1). Celkové zarovnanie medzi predpovedanými a pozorovanými hodnotami naznačuje, že ANN zachytáva hlavné trendy v únave, aj keď jednotlivé predpovede vykazujú znateľnú variabilitu. Spodný panel Obrázka 4 zobrazuje rezíduá (zelená) s kubickou normou rezíduí 10,5899. To naznačuje, že chyby predikcie sú väčšinou sústredené okolo nuly a že nie je prítomné žiadne systematické skreslenie.

Teoreticky by optimalizačný proces siete mohol prebiehať až 1 000 iterácií, aby sa minimalizovala chyba. V tomto prípade sa trénovanie zastavilo po 10 iteráciách a najlepšie skóre validácie sa dosiahlo v epoche 4 (MSE = 0,67086) (obrázok 5). Malý rozdiel medzi krivkami trénovania, validácie a testovania tiež naznačuje, že sieť nezažila podstatné preplnenie.

Systém poskytuje popisnú štatistiku pre každú premennú a umožňuje priame porovnanie pozorovaných skóre únavy s tými, ktoré predpovedala sieť. V pôvodnom súbore údajov sa únava pohybovala od 1 („nikdy“) do 5 („často“) s priemerom 2,65 a štandardnou odchýlkou 1,15, čo naznačuje značnú variabilitu medzi účastníkmi. Naproti tomu predpovedané hodnoty sa pohybovali od 1,79 do 4,64 s priemerom 2,80 a nižšou štandardnou odchýlkou 0,49, čo ukazuje, že predpovede boli hustejšie zoskupené okolo stredu stupnice a že celkový rozsah bol komprimovaný. Táto kompresia predpovedaných hodnôt (priemer 2,80, SD 0,49) v porovnaní s pozorovanými skóre (priemer 2,65, SD 1,15) je klasickým znakom nedostatočného prispôsobenia, čo naznačuje, že model nie je dostatočne komplexný alebo mu chýbajú informatívne prvky na zachytenie plnej variability v údajoch. Na výstupy siete bol použitý kubický model, aby sa zabezpečila hladká aproximácia tohto všeobecného trendu a interpolačná funkcia. Keď boli testované špecifické hodnoty x (napríklad 35, 300 a 480), zodpovedajúce predpokladané úrovne únavy sa všetky nachádzali v úzkom pásme okolo 2 – 3, čo potvrdzuje, že model zachytáva centrálnu tendenciu, ale podceňuje ju. extrémne reakcie a pozorovaná variabilita.

Výsledky

Metriky výkonnosti

Chyby modelu boli skúmané pomocou histogramu chýb vrátane trénovacích, validačných a testovacích vzoriek. Väčšina chýb sa zhlukovala okolo nuly, čo naznačuje, že predpokladané skóre únavy boli vo všeobecnosti blízke pozorovaným hodnotám a že nebola zjavná žiadna silná systematická odchýlka. Histogram však ukazuje, že presnosť predikcie sa u jednotlivých jednotlivcov líšila, čo je v súlade so zložitosťou problému a obmedzenou veľkosťou súboru údajov.

Na vizuálne posúdenie prediktívnej výkonnosti ANN v rámci trénovacích, validačných, testovacích a celkových súborov údajov boli použité regresné grafy (obrázok 6). V každom paneli sú pozorované (cieľové) skóre únavy vynesené oproti zodpovedajúcim predpovedaným hodnotám spolu s priradenou regresnou priamkou (plná čiara) a jednotkovou priamkou Y = T (prerušovaná), ktorá predstavuje dokonalú zhodu. Vo všetkých podmnožinách sú regresné sklony veľmi plytké (trénovanie = 0,097, validácia = 0,074, test = 0,032, celkovo = 0,083), čo naznačuje iba slabú lineárnu korešpondenciu medzi pozorovanými a predpovedanými skóre. Široký rozptyl bodov okolo jednotkovej priamky potvrdzuje, že model vysvetľuje iba malú časť rozptylu únavy a predpovedá prevažne hodnoty blízko priemeru, čím podceňuje extrémne úrovne únavy.

Aplikácia vizuálneho rozhrania

Bol navrhnutý a optimalizovaný model ANN na predpovedanie vplyvu každej vstupnej premennej na výstupnú premennú úrovne únavy. Aby bol tento model použiteľný mimo MATLABu, bolo navrhnuté grafické používateľské rozhranie (obrázok 7). Používatelia môžu zadať hlavné rizikové faktory (veková skupina, pohlavie, vzdialenosť telefónu počas spánku, roky používania a čas denného používania) a získať okamžitú predpoveď úrovne únavy. Výsledok sa zobrazuje ako číselné skóre a farebný indikátor od zelenej (nízka únava) po červenú (vysoká únava), čo uľahčuje interpretáciu a podporuje základné preventívne rady. Keďže model bol trénovaný na relatívne malej množine údajov, jeho predpovede by sa mali považovať za dôkaz konceptu, ktorý bude potrebné ďalej spresniť s väčšou a rozmanitejšou vzorkou. Výsledok sa zobrazuje číselne aj s farebne odlíšeným indikátorom od zelenej (nízka únava) po červenú (vysoká únava). To ponúka jednoduchý a intuitívny spôsob vizualizácie rizika a usmerňovania preventívnych stratégií.

Obrázok 7. Vizuálne aplikačné rozhranie na predpovedanie úrovne únavy spojenej s používaním mobilného telefónu. Záver.

Diskusia

Táto štúdia predstavuje prvý pokus modelovať únavu spojenú s používaním mobilného telefónu pomocou umelej neuronálnej siete (ANN). Model dokázal spracovať viacero expozičných a sociodemografických premenných súčasne a zachytiť niektoré všeobecné trendy v údajoch.

Jeho prediktívny výkon však zostal skromný, s nízkym koeficientom determinácie a tendenciou znižovať skóre únavy okolo priemeru. Tieto zistenia naznačujú, že pri súčasnom súbore prediktorov a veľkosti vzorky by sa model mal považovať skôr za dôkaz konceptu než za nástroj na predikciu individuálneho rizika.

Treba uznať niekoľko obmedzení. Analýza sa opierala o údaje hlásené samotnými respondentmi z relatívne malej prierezovej vzorky a zahŕňala obmedzený počet premenných expozície a životného štýlu. Budúce štúdie by mali zahŕňať väčšie a rozmanitejšie vzorky, objektívne ukazovatele používania telefónov (napríklad záznamy o čase strávenom pred obrazovkou a záznamy o používaní priamo extrahované z telefónu) a validované meracie nástroje pre únavu aj potenciálne mätúce faktory, ako je Chalderova škála únavy alebo škála závažnosti únavy pre únavu, a nástroje ako Pittsburghský index kvality spánku a škála vnímaného stresu na lepšiu charakterizáciu spánku a psychického stresu. Longitudinálny dizajn by tiež... byť cenné pre stanovenie časového vzťahu medzi vzormi expozície a vznikom alebo pretrvávaním únavy.

Z metodologického hľadiska by ďalšia práca mala porovnať súčasný prístup ANN s pokročilejšími modelmi strojového učenia, ako sú Gradient Boosting a Random Forests, ako aj s tradičnou regresiou, aby sa zistilo, či flexibilnejšie algoritmy dokážu zlepšiť prediktívny výkon a kalibráciu. Okrem toho by použitie moderných techník interpretovateľnosti, ako je SHAP (SHapley Additive ExPlanations) alebo permutačné dôležitosti, mohlo pomôcť objasniť relatívny príspevok každého prediktora a poskytnúť transparentnejší pohľad na to, ako sa generujú výstupy modelu. Keďže sa bezdrôtové technológie neustále vyvíjajú a vzorce používania sa menia, vylepšené modely ANN a strojového učenia trénované na bohatších a lepšie charakterizovaných súboroch údajov môžu prispieť k presnejšiemu pochopeniu únavy spojenej s používaním mobilných telefónov a pomôcť informovať o budúcich odporúčaniach v oblasti verejného zdravia.

Záver

Stručne povedané, ANN zachytila široké vzorce spájajúce faktory súvisiace s používaním mobilných telefónov s únavou, ale jej prediktívna presnosť bola obmedzená. Za súčasných podmienok by sa mala považovať skôr za prieskumný krok, ktorý preukazuje uskutočniteľnosť, než za model vhodný na predikciu na individuálnej úrovni. Posilnenie budúcich štúdií s väčšími vzorkami, objektívna expozícia

Merania, validované nástroje a porovnávacie modelovanie môžu podstatne zlepšiť výkon a zvýšiť hodnotu prístupov strojového učenia v tejto oblasti.

Poďakovanie

Autori ďakujú všetkým účastníkom za vyplnenie dotazníka.

Etické schválenie

Písomný súhlas bol získaný od všetkých účastníkov a štúdia bola vykonaná v súlade s Helsinskou deklaráciou.

Financovanie

Na túto štúdiu neboli získané žiadne finančné prostriedky.

Konflikty záujmov

Autori uvádzajú, že neexistujú žiadne konkurenčné záujmy, ktoré by bolo potrebné deklarovať.

Deklarácia o generatívnej umelej inteligencii a technológiách s podporou umelej inteligencie

Počas prípravy tejto práce autori použili umelú inteligenciu (ChatGPT 5.1) na zlepšenie jazykovej kvality textu. Následne skontrolovali a v prípade potreby upravili obsah a preberajú plnú zodpovednosť za obsah publikácie.

Referencie

[1] Ahlbom A, Green A, Kheifets L, Savitz D, Swerdlow A. Epidemiológia zdravotných účinkov vystavenia rádiofrekvenciám. Environ Health Perspect. 2004;112(17):1741–54.[DOI: 10.1289/ehp.7306]

[2] Kim KH, Kabir E, Jahan SA. Používanie mobilného telefónu a pohľad na jeho potenciálne vplyvy na ľudské zdravie. Environ Monit Assess. 2016;188(4):221.[DOI: 10.1007/s10661-016-5227-1]

[3] Svetová zdravotnícka organizácia. Elektromagnetické polia. Svetová zdravotnícka organizácia – India. [citované 8. augusta 2025].[Odkaz]

[4] Oftedal G, Wilén J, Sandström M, Mierna KH. Príznaky vyskytujúce sa v súvislosti s používaním mobilného telefónu. Occup Med. 2000;50(4):237–45. [DOI: 10.1093/occmed/50.4.237]

[5] Adams JA, Galloway TS, Mondal D, Esteves SC, Mathews F. Vplyv mobilných telefónov na spermie kvalita: Systematický prehľad a metaanalýza. Environ Int. 2014;70:106–112.[DOI: 10.1016/j.envint.2014.04.015]

[6] Schoeni A, Roser K, Röösli M. Výkon pamäte, bezdrôtová komunikácia a vystavenie rádiofrekvenčným elektromagnetickým poliam: Prospektívna kohortová štúdia u adolescentov. Environ Int. 2015;85:343–51. [DOI: 10.1016/j.envint.2015.09.025]

[7] Salmaniannezhad H, Salmaniannezhad H, Zarei Moghaddam R. Skúmanie vplyvu elektromagnetických vĺn na ľudské a zvieracie telá a spôsoby ich ochrany. Int J Med Investig. 2024;13(3):99–118.

8] Röösli M. Rádiofrekvenčné elektromagnetické pole expozícia a nešpecifické príznaky zlého zdravotného stavu. Environ Res. 2008;107(2):277–287.[DOI: 10.1016/j.envres.2008.02.003]

[9] Durusoy R, Hassoy H, Özkurt A a kol. Používanie mobilných telefónov, úrovne elektromagnetického poľa v školách a súvisiace symptómy: Prierezový prieskum medzi 2150 študentmi stredných škôl v Izmire. Environ Health. 2017;16:51.[DOI: 10.1186/s12940-017-0257-x]

[10] Bosch-Capblanch X, Esu E, Oringanje CM, Dongus S, Jalilian H, Eyers J a kol. Účinky vystavenia rádiofrekvenčným elektromagnetickým poliam na symptómy hlásené samotnými ľuďmi: Systematický prehľad experimentálnych štúdií na ľuďoch. Environ Int. 2024;187:108612. [DOI: 10.1016/j.envint.2024.108612]

[11] Rumelhart DE, Hinton GE, Williams RJ. Učiace sa reprezentácie spätným šírením chýb. Nature. 1986;323(6088):533–6.[DOI: 10.1038/323533a0]

[12] Abraham A. Umelé neurónové siete. In: Sydenham PH, Thorn R, editori. Príručka návrhu meracích systémov. Wiley; 2005. s. 901–8. [DOI: 10.1002/0471497398.mm421]

[13] Bouharati S, Braham-Chaouch W, Benzidane C, Boumaiza S. Analýza tepelnej zotrvačnosti v saharských biotopoch pomocou umelých neuronálnych sietí: Prípad architektonických štýlov v regióne Adrar (Alžírsko). Am J Environ Eng Sci. 2014;1(4):69–72.[Odkaz]

[14] Schmidhuber J. Hlboké učenie v neurónových sieťach: Prehľad. Neural Netw. 2015;61:85–117.[DOI: 10.1016/j.neunet.2014.09.003]

-

[15] Goodfellow I., Bengio Y., Courville A. Hlboké učenie. MIT Press; 2016.[Odkaz]

[16] Jaiswal A, Zadeh MZ, Hebri A, Makedon F. Posudzovanie únavy pomocou multimodálnych nositeľných senzorov a strojového učenia. arXiv. 2022.[DOI: 10.48550/arXiv.2205.00287]

[17] Svetová lekárska asociácia. Helsinská deklarácia: Etické princípy pre lekársky výskum zahŕňajúci ľudské subjekty. JAMA. 2013;310(20):2191–4. [DOI: 10.1001/jama.2013.281053]