Ovisnost koncentracije radona o okolišnim parametrima - višestruki linearni regresijski model

Pejak, Iva

Master's thesis / Diplomski rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Geotechnical Engineering / Sveučilište u Zagrebu, Geotehnički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:130:193307

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-26**

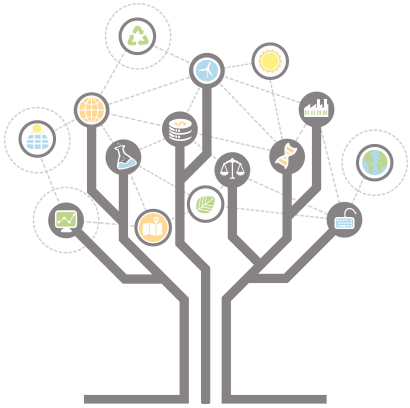

Repository / Repozitorij:

Repository of Faculty of Geotechnical Engineering - Theses and Dissertations

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

GEOTEHNIČKI FAKULTET

IVA PEJAK

OVISNOST KONCENTRACIJE RADONA O OKOLIŠNIM PARAMETRIMA – VIŠESTRUKI LINEARNI REGRESIJSKI MODEL

DIPLOMSKI RAD

VARAŽDIN, 2020.

Sazivam članove ispitnog povjerenstva

za _____ u _____ sa

Obranu ovog rada kandidat će vršiti i pred

ispitnim povjerenstvom u Varaždinu

Varaždin, _____

Predsjednik
ispitnog povjerenstva:

Izv. prof. dr. sc. Igor Petrović

Članovi povjerenstva

1) Izv. prof. dr. sc. Anita Ptiček Simočić
2) Izv. prof. dr. sc. Sanja Varač
3) Dr. sc. Davor Stanko
4) Izv. prof. dr. sc. Nikola Sakač

SVEUČILIŠTE U ZAGREBU

GEOTEHNIČKI FAKULTET

DIPLOMSKI RAD

OVISNOST KONCENTRACIJE RADONA O OKOLIŠNIM PARAMETRIMA – VIŠESTRUKI LINEARNI REGRESIJSKI MODEL

KANDIDAT:

Iva Pejak

Pejaz Iva

MENTOR:

izv.prof.dr.sc. Anita Ptiček Siročić

KOMENTOR:

izv.prof.dr.sc. Sanja Kovač

NEPOSREDNI VODITELJ:

dr.sc. Davor Stanko

VARAŽDIN, 2020.

Sveučilište u Zagrebu
Geotehnički fakultet

ZADATAK ZA DIPLOMSKI RAD

Pristupnica: IVA PEJAK

Matični broj: 243 - 2018./2019.

Smjer: UPRAVLJANJE VODAMA

NASLOV DIPLOMSKOG RADA:

OVISNOST KONCENTRACIJE RADONA O OKOLIŠNIM PARAMETRIMA - VIŠESTRUKI LINEARNI REGRESIJSKI MODEL

Rad treba sadržati: 1. Uvod
2. Radon
3. Regresijska analiza
4. Eksperimentalni dio
5. Rezultati i rasprava
6. Zaključak
7. Literatura

Pristupnica je dužna predati mentoru jedan uvezan primjerak diplomskog rada sa sažetkom. Vrijeme izrade diplomskog rada je od 45 do 90 dana.

Zadatak zadan: 10.03.2020. Rok predaje: 07.09.2020.

Mentor: Izv.prof.dr.sc. Anita Ptiček Siročić

Drugi mentor/komentor: Izv.prof.dr.sc. Sanja Kovač

Predsjednik Odbora za nastavu: Izv.prof.dr.sc. Igor Petrović

Neposredni voditelj: Dr.sc. Davor Stanko

REPUBLIKA HRVATSKA
GEOTEHNIČKI FAKULTET
SVEUČILIŠTE U ZAGREBU
VARAŽDIN

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad pod naslovom

OVISNOST KONCENTRACIJE RADONA O OKOLIŠNIM PARAMETRIMA – VIŠESTRUKI LINEARNI REGRESIJSKI MODEL

rezultat mog vlastitog rada koji se temelji na istraživanjima te objavljenoj i citiranoj literaturi te je izrađen pod mentorstvom **izv.prof.dr.sc. Anita Ptiček Siročić** i komentorstvom **izv.prof.dr.sc. Sanja Kovač.**

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

U Varaždinu, 31.08.2020.

Ime i prezime: Iva Pejak

Vlastoručni potpis: Pejak Iva

IZJAVA MENTORA O POSTOTKU SLIČNOSTI DIPLOMSKOG RADA S VEĆ OBJAVLJENIM RADOVIMA

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad pod naslovom

OVISNOST KONCENTRACIJE RADONA O OKOLIŠNIM PARAMETRIMA – VIŠESTRUKI LINEARNI REGRESIJSKI MODEL

pregledan anti-plagijat programskim paketom PlagScan te da postotak sličnosti cjelovitog završnog rada, s već objavljenim radovima, ne prelazi 20 %, kao i da pojedinačni postotak sličnosti završnog rada sa svakom literaturnom referencom pojedinačno ne prelazi 5 %.

U Varaždinu, 31.08.2020

Izv. prof. dr. sc. Anita Ptiček Siročić

(Mentor)

(Vlastoručni potpis)

Veliku zahvalnost, u prvom redu, dugujem mentorici izv.prof.dr.sc. Aniti Ptiček Siročić, kao i komentorici izv.prof.dr.sc. Sanji Kovač te neposrednom voditelju dr.sc. Davoru Stanku, koji su mi svojim savjetima pomogli pri izradi ovog diplomskog rada i što su uvijek imali strpljenja i vremena za moje brojne upite.

Također, zahvaljujem svim svojim prijateljima i prijateljicama, koji su uvijek bili uz mene i bez kojih cijeli ovaj tijek mog studiranja ne bi prošao tako lako i zabavno.

Zahvaljujem svim sudionicima koji su mi pomogli i otvorili svoja vrata domova, vikendica i poslovnih objekata kako bi mogla prikupiti podatke za ovaj rad.

Posebnu zahvalnost iskazujem cijeloj svojoj obitelji koja me je uvijek podržavala i upućivala na pravi put.

I na kraju, najveću zaslugu za ono što sam postigla pripisujem svojim roditeljima, koji su uvijek bili TU, uz mene, u teškim ili sretnim trenutcima i bez kojih sve ovo što sam dosad postigla ne bi bilo moguće!

SAŽETAK

OVISNOST KONCENTRACIJE RADONA O OKOLIŠNIM PARAMETRIMA – VIŠESTRUKI LINEARNI REGRESIJSKI MODEL

Radon (^{222}Ra) je prirodni radioaktivni plin kojeg se ne može vidjeti, okusiti ni namirisati. Ljudi su neprestano izloženi određenoj koncentraciji radona koji je nazočan u zemlji, vodi, zraku i hrani. Koncentracija radona u zraku koja se udiše poprilično je niska. Unutar stambenog prostora može biti vrlo visoka zbog toga jer radon može prodrijeti iz temeljnog tla preko podruma u samu građevinu [1].

U radu je provedena korelacijska analiza okolišnih parametara te je pomoću modela višestruke regresije određena statistička povezanost između okolišnih parametara (temperatura, vlažnost i atmosferski tlak) i koncentracije radona [2]. Mjerenja su provedena na više lokacija sjeverozapadne Hrvatske u različitim stambenim objektima. Rezultati su ukazali na postojanje povezanosti između pojedinih okolišnih parametara i koncentracije radona na pojedinim lokacijama odnosno uočeno je opadanje koncentracije radona s povećanjem atmosferskog tlaka te povećanje koncentracije radona s povećanjem vlažnosti zraka.

Ključne riječi: radon, temperatura, vlažnost, atmosferski tlak, regresijski model

ABSTRACT

DEPENDENCE OF RADON CONCENTRATION ON ENVIRONMENTAL PARAMETERS – MULTIPLE LINEAR REGRESSION MODEL

Radon (^{222}Ra) is natural radioactive gas that cannot be seen, tasted or smelled. People are daily exposed to a certain concentration of radon that is present in soil, water, air and food. The concentration of radon in the inhaled air is quite low. Inside a living space the concentration of radon can be very high because radon can permeate from a foundation soil over a basement into a building itself.

The paper shows a correlation analysis of environmental parameters by using the model of multiple regressions. It defines certain statistical relations between environmental parameters such as temperature, humidity and atmospheric pressure and radon concentration.. Measurements were carried out at several locations in various residential buildings in north-western Croatia. The results indicated that individual environmental parameters and radon concentration at individual locations were connected. For example, at one location the concentration of radon was decreasing if atmospheric pressure was increasing. Measurements at another location indicated that the concentration of radon was increasing if air humidity was increasing.

Key words: radon, temperature, humidity, atmospheric pressure, regression model

SADRŽAJ

1. UVOD 1

2. RADON 2

2.1. Radioaktivnost 2

2.2. Zakon radioaktivnog raspada 5

2.3. Izvori radona u okolišu 8

2.4. Načini mjerenja koncentracije radona 11

2.5. Utjecaj radona na ljudsko zdravlje 13

3. REGRESIJSKA ANALIZA 14

3.1. Linearni regresijski model 15

3.2. Višestruki regresijski model 19

3.3. Nelinearni regresijski model 23

4. EKSPERIMENTALNI DIO 25

4.1. Opis lokacija 25

4.2. Mjerenje koncentracije radona 26

5. REZULTATI I RASPRAVA 27

5.1. Prikaz podataka dobivenih mjerenjima 27

5.2. Uspostava višestrukog linearnog regresijskog modela 30

5.2.1. Model višestruke regresije – lokacija Beletinec 34

5.2.2. Model višestruke regresije – lokacija Vinica 35

5.2.3. Model višestruke regresije – lokacija Herešin 37

6. ZAKLJUČAK 40

7. LITERATURA 41

POPIS SLIKA I TABLICA 43

1. UVOD

Radon (^{222}Rn) je prirodni radioaktivni element u plinovitom stanju, glavni izvor je tlo. Nastaje radioaktivnim raspadom urana, koji se nalazi u Zemljinoj kori. Velika koncentracija radona u okolišu su glavni uzrok nastanka smrtonosnog karcinoma pluća (udisanjem) te karcinom želuca (unošenjem vode u organizam).

Radon je plin bez boje i mirisa, za detekciju i mjerenje potrebni su posebni mjerni uređaji. Koncentracija aktivnosti radona je broj radioaktivnog raspada atoma radona u jedinici vremena i obujmu. Mjerna jedinica je bekerelima po kubnom metru (Bq/m^3), a skraćeno se naziva koncentracija radona. Koncentracija radona mijenja se u vremenu, pa tako i tijekom cijele godine. Za što pouzdaniju i učinkovitiju procjenu doze zračenja radona u okolišu, poželjno je provoditi mjerenja minimalno godinu dana. Mjerenja se vrše raznim detektorima nuklearnih tragova koji su pasivno izloženi u prostoru u kojem se svakodnevno boravi [1].

Sukladno Direktivi Vijeća 2013/59/Euratom o osnovnim sigurnosnim standardima za zaštitu od opasnosti koje potječu od izloženosti ionizirajućem zračenju za zemlje članice EU, utvrđeno je da referentna razina za radon u zatvorenim prostorima i na radnim mjestima ne bi trebala prelaziti 300 Bq/m^3. Navedena referentna razina je prenesena i u hrvatsko zakonodavstvo Pravilnikom o granicama zračenja, preporučenom dozom ograničenja i procjenjivanju osobnog zračenja („Narodne novine“ broj 38/18) [3]. U Republici Hrvatskoj su provedena istraživanja u stambenim prostorima, te koncentracija radona oscilira od županije do županije. Najveću izmjerenu koncentraciju radona imaju Istarska, Karlovačka, Ličko – senjska županije, raspon od 101 – 200 Bq/m^3, dok su u Baranji, Požeško – slavonskoj županiji koncentracije radona niže i iznose od 51 do 100 $Bq/^3$ [1].

Cilj ovog rada bio je pomoću regresijskog modela istražiti povezanost okolišnih parametara odnosno temperature, vlažnosti i atmosferskog tlaka s koncentracijom radona u zraku u zatvorenim prostorima na nekoliko lokacija na području sjeverozapadne Hrvatske.

2. RADON

2.1. Radioaktivnost

U prirodi postoje nestabilne i stabilne atomske jezgre. Nestabilne atomske jezgre su one jezgre koje se spontano raspadaju izbacujući alfa, beta i gama zračenja, čime prelaze u stabilnije stanje. Procesi, gdje nestabilne atomske jezgre prelaze u stabilnije stanje, nazivaju se procesi radioaktivnosti. Zračenja koja nastaju uslijed procesa radioaktivnosti nazivaju se radioaktivna zračenja te spadaju u ionizirajuća zračenja. Ionizirajuće zračenje je zračenje koje u međudjelovanju izbacuje elektron iz elektronskog omotača, čime on postaje ion i zahtijeva energiju.

Radioaktivnost se može povezati sa stabilnošću jezgre atoma, a atomska jezgra se nalazi u središnjem dijelu atoma. Kako bi se što bolje shvatio pojam radioaktivnosti treba povezati nekoliko osnovnih pojmova iz nuklearne fizike koja proučava atomsku jezgru (struktura atoma i sile koje djeluju).

Dva su oblika u kojima se javlja materija u prirodi, tvar i fizičko polje. Tvar je svako tijelo koje ima masu (na primjer molekule, atomi), a fizičko polje je prostor u kojem djeluju sile (elektromagnetske, nuklearne). Najjednostavnija forma postojanja tvari je kemijski element, a najmanja čestica kemijskog elementa je atom. Atom je sačinjen od elementarnih čestica, točnije od protona, elektrona i neutrona. Proton je pozitivnog električkog naboja, elektron ima negativan električki naboj, a neutron je električki neutralan, odnosno, bez naboja. Svaki atom građen je od atomske jezgre koja je pozitivno nabijena i negativno nabijenog elektronskog omotača, u kojem se gibaju elektroni. Atomska jezgra je pozitivno nabijena, jer se u njoj nalaze protoni i neutroni, odnosno nukleoni. Neutron ima masu jednaku masi protona. Atomski broj (Z) je broj protona u jezgri atoma i on je ujedno jednak broju elektrona u elektronskom omotaču tog atoma. Atomi koji sadrže veliki broj protona u jezgri, odnosno, kojima je atomski broj velik, su nestabilni. Protonski broj je jednak broju protona, a neutronski broj (N) je jednak broju neutrona koji se nalazi u istoj jezgri atoma. Nuklid koji sadrži isti broj protona, a različit broj neutrona naziva se izotop. Dakle, izotop je atom istog kemijskog elementa koji ima isti broj protona i elektrona, a različit broj neutrona, a u periodnom sustavu elemenata nalaze se na istom mjestu. Jednaki su po broju protona, a

međusobno se razlikuju po broju neutrona u jezgri atoma te po masenom broju. Oni imaju ista kemijska svojstva, a različita fizikalna. Za primjer izotopa uzet je kemijski element radon (Rn), a njegovi poznati izotopi su aktinon (^{219}Rn), toron (^{220}Rn) i radon (^{222}Rn) [4].

Svojstvo nuklida je da spontano odašilju radioaktivno zračenje u obliku elektromagnetskog zračenja. Postoji prirodna radioaktivnost i umjetna radioaktivnost. Prirodna radioaktivnost je vrsta ionizirajućeg zračenja koja potječe od prirodnih radioaktivnih zračenja kojemu su izložena sva živa bića. O umjetnoj radioaktivnosti se govori ako je radioaktivni nuklid stvoren umjetnom nuklearnom reakcijom. Zračenja koja nastanu radioaktivnošću razlikuju se po prodornosti, električnom naboju i po procesima koji dovode do emisije pa se tako razlikuju 3 vrste radioaktivnog zračenja: α-alfa, β-beta, γ-gama zračenja.

Alfa (α) zračenje u zraku je dometa 2 – 8 cm (ovisno o energiji) te ga može zaustaviti papir, koža i odjeća. Beta (β) zračenje u zraku je dometa do 10 m i može ga zaustaviti aluminijski lim, plastika te staklo. Gama (γ) zračenje u zraku je dometa do 100 m, može ga zaustaviti olovna ploča i zemlja. Prodor radioaktivnog zračenja prikazan na Slici 1.

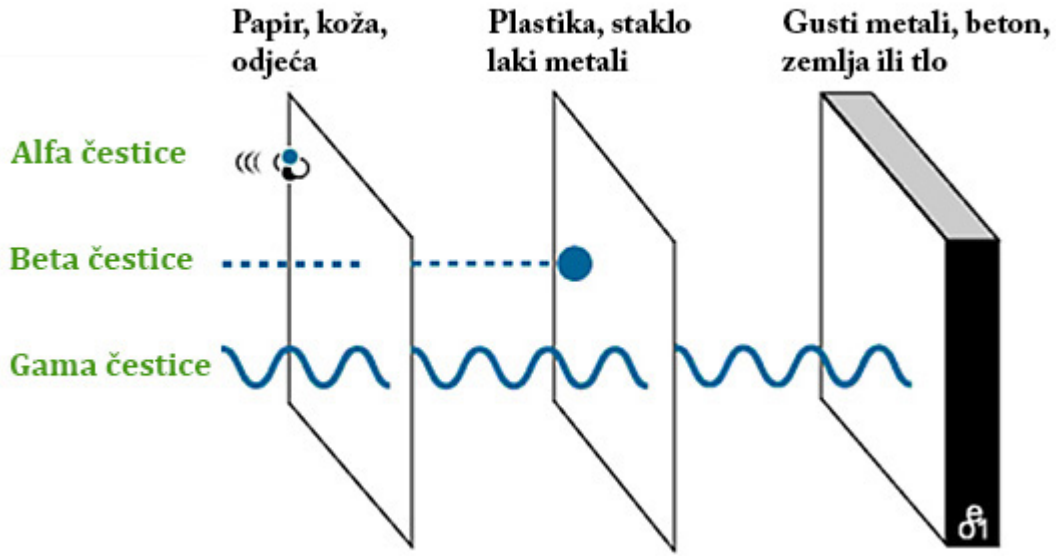

Slika 1. Prodornost α, β i γ zračenja [5]

- *α – raspad*

α radioaktivnost je proces promjene atomske jezgre pri kojoj jezgra emitira alfa česticu. Alfa čestica je atom helija ($^4_2$He) te se radi o vrlo čvrstom povezanom sustavu od 2 protona i 2 neutrona. Primjer alfa raspada je raspad radija. Radij je alfa emiter, odnosno emisijom alfa čestica prelazi u stabilnije stanje i nastaje plin radon. Radon je također radioaktivan plin, koji se radioaktivno raspada, odnosno, događa se niz raspada dok ne postigne stabilnost jezgre (Slika 2.). α čestice zbog svoje velike mase nisu prodorne te imaju domet u zraku svega nekoliko centimetara. Alfa radioaktivni izvori nisu opasni kao vanjski radioaktivni izvori, no opasne su one alfa čestice koje dođu u čovjekovo tijelo, budući da imaju veliku snagu ionizacije [4].

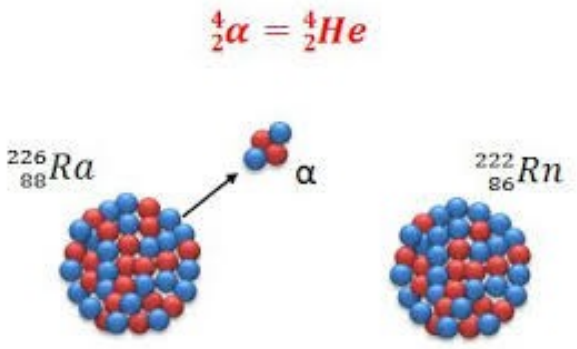

Slika 2. Raspad radija-226 [4]

- *β – raspad*

β radioaktivnost je proces u kojem radioaktivna jezgra spontano mijenja svoju građu, odnosno jedan proton pretvori u neutron ili obrnuto. Razlikuju se tri raspada: β-plus raspad, β-minus raspad i elektronski uhvat. U prirodnim radioaktivnim nizovima pri beta minus raspadu jedan neutron u jezgri raspadne se na elektron, antineutrino i proton (Slika 3.). Prilikom umjetne izazvane radioaktivnosti može doći i do plus raspada, to jest, emisije pozitrona i neutrina. Protonski broj se smanji za jedan, a masni broj atoma ostaje isti [6]. Prodornost β - čestica je veća nego prodornost α - čestica, a u zraku imaju domet do nekoliko metara. Vanjski radioaktivni izvor može prouzročiti oštećenja na koži, tkivu ili očima.

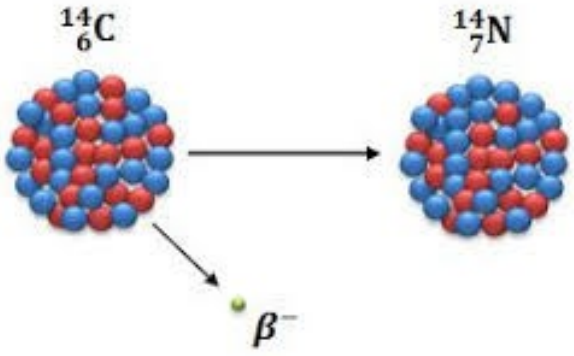

Slika 3. β-minus raspad

- *γ – raspad*

γ zračenje je promjena nuklida bez promjene masenog i atomskog broja (Slika 4.). Gama radioaktivnost je prijelaz između stanja više pobuđenosti jezgre atoma u stanje niže pobuđenosti, to jest, osnovno stanje. Gama zračenje je elektromagnetsko zračenje visoke frekvencije koje se pritom emitira. Ako jezgra, koja je doživjela alfa ili beta raspad ostane u reaktivnom stanju, tada nastaje gama zračenje koje je elektromagnetske prirode. Tokom procesa se emitira čista energija, pri čemu jezgra dolazi u stabilnije stanje. Gama zrake postoje samo dok imaju energiju, a kada potroše energiju one prestaju postojati.

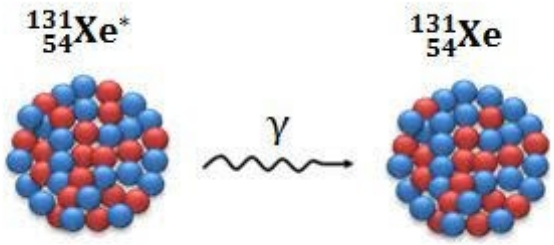

Slika 4. γ-raspad [4]

2.2. Zakon radioaktivnog raspada

Kao što je već spomenuto, u prirodi postoje stabilne i nestabilne jezgre atoma. Nestabilne jezgre će postojati neko vrijeme te se one spontano nakon nekog vremena same od sebe raspadaju. Spontani raspad nestabilne jezgre je proces statističke prirode, jer se ne može predvidjeti kada će se radioaktivna jezgra raspasti. Jezgra koja se raspada, proces raspadanja radi po zakonu radioaktivnog raspada. Zakon radioaktivnog raspada govori koliko će se radioaktivnih jezgri atoma raspasti u nekom uzorku tvari i u nekom vremenskom intervalu.

U svrhu dobivanja konačnog broja raspadnutih jezgri, zakon radioaktivnog raspada ovisi o početnom stanju, odnosno o broju radioaktivnih jezgri N_0. Ovisi i o vremenu poluraspada T, a N je broj radioaktivnih jezgri u promatranom vremenu t.

$$N = N_0 * 2^{\frac{1}{T}} \tag{2.1}$$

Vrijeme poluraspada T, je vrijeme u kojem je potrebno da se početni broj atoma ograniči na polovinu početnog broja, gdje je λ konstanta radioaktivnog raspada. Konstanta radioaktivnog raspada je različita za svaki radioaktivni nuklid.

$$T = \frac{\ln 2}{\lambda} \tag{2.2}$$

Također, zakon radioaktivnog raspada može se izraziti pomoću konstante radioaktivnog raspada te glasi:

$$N = N_0 * e^{-\lambda t} \tag{2.3}$$

Broj atoma koji se raspadne u vremenu je brzina raspada. Brzina raspada se opisuje aktivnošću. Mjerna jedinica u međunarodnom sustavu za aktivnost je 1 *becquerel* (Bq).

$$1\ \text{Bq} = \ 1\ \text{raspad}/1\ \text{sekunda} \tag{2.4}$$

Aktivnost (A) se izražava umnoškom konstante radioaktivnog raspada (λ) i broja atoma koji se raspadne (N) [6].

$$A = \lambda * N \tag{2.5}$$

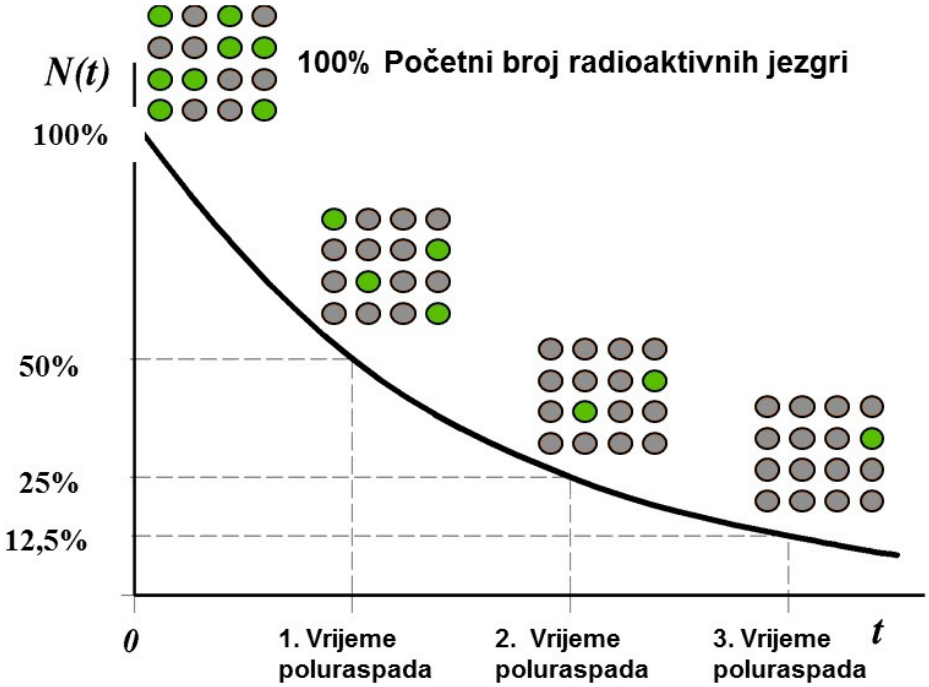

Slika 5. Krivulja radioaktivnog raspada i vremena poluraspada jezgre atoma [5]

Zračenje je proces koji podrazumijeva prijenos energije kroz tvari u obliku elektromagnetskih valova. Proces u kojim atomi gube, a ponekad i dobivaju elektrone te od neutralnih postaju električki nabijene čestice naziva se ionizacija.

Svako ionizirajuće zračenje je štetno, najviše za živčano tkivo. Tkivo se može regenerirati, ali bez trajnog efekta. Ponekad se opasnost od zračenja respektira, jer postoji odgoda između izloženosti zračenju i drugih posljedica. U ionizirajuće zračenje ubrajaju se UV zračenja, RTG, gama zrake, dok se zračenja koja emitiraju vodovi, razni elektronski uređaji i mobiteli nazivaju neionizirajućim zračenjem (Slika 6.) [7].

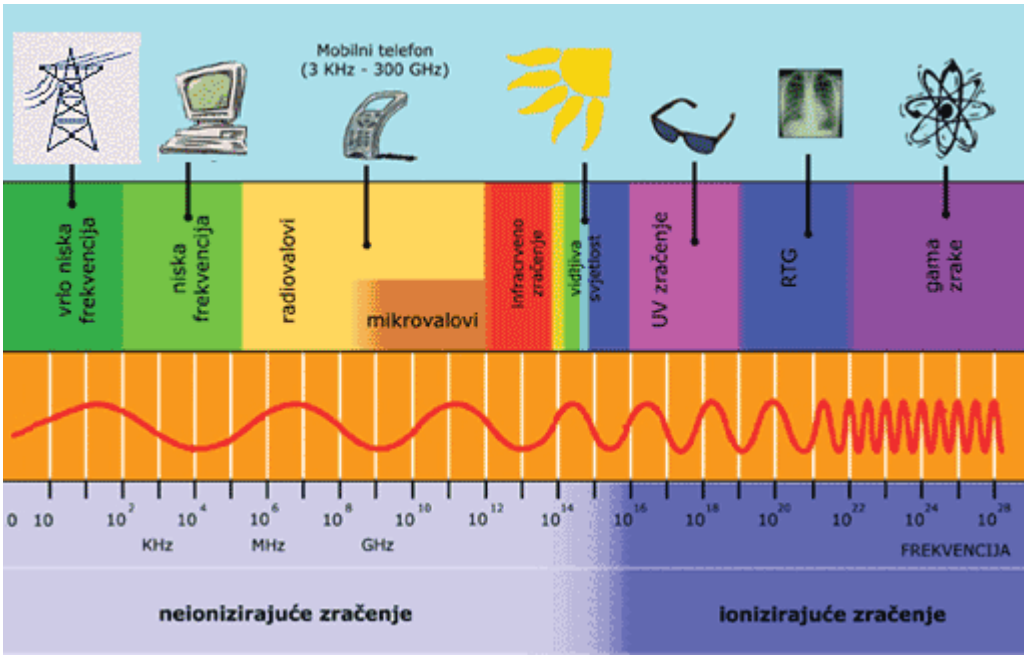

Slika 6. Spektar elektromagnetskog zračenja [8]

Mjerna jedinica za doziranje zračenja je *sivert* (*Sv*). 1 Sv je količina zračenja koja ima isti biološki efekt kao i kad 1 kg tjelesnog tkiva razgradi 1 J gama zraka. Uz mjernu jedinicu sivert, ponekad se koristi *rem*, koji iznosi 0,01 Sv [7].

2.3. Izvori radona u okolišu

Prirodni i umjetni izvori radioaktivnog zračenja su izvori koji mogu direktno ili indirektno djelovati na čovjeka te na okoliš. Prirodni izvor radioaktivnosti je pojava u prirodi bez vanjskih utjecaja gdje dolazi do raspadanja jezgre atoma.

U prirodne izvore zračenja se ubrajaju:

- termalni izvori
- materijali za gradnju
- zemaljski izvori
- kozmički ili svemirski izvori
- radioaktivni elementi u našem organizmu.

Umjetni izvori su:

- radioterapija
- nuklearne nesreće
- nuklearna medicina
- radioterapija
- primjena zračenja u medicini
- nuklearne elektrane.

Uran, radij, torij i njihovi radioaktivni derivati su primarni radioaktivni elementi u prirodi. Većina tog prirodnog zračenja potječe od plina radona, koji nastaje kao produkt raspada torija i uranija. Izvor i količina radona prisutnih u okolišu su prirodne, ali pod utjecajem antropogenih aktivnosti. Iz Slike 7. je vidljivo da najveći dio radijacije koju stanovništvo prima dolazi iz prirodnih izvora te je izlaganje tom dijelu radijacije neizbježno. Također, najveći postotak prirodne radijacije zapravo dolazi od radona [9].

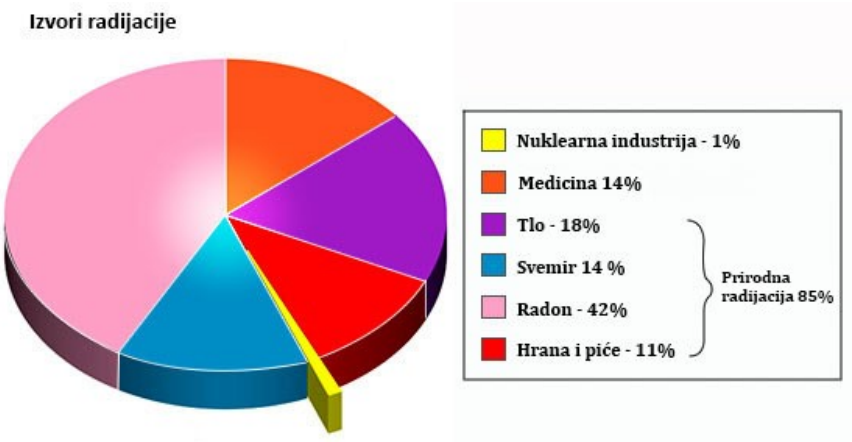

Slika 7. Izvori radijacije na Zemlji [5]

Tlo koje sadrži radij glavni je izvor radona, budući da plin radon nastaje radioaktivnim raspadom radija. Kolika će biti koncentracija radona u tlu i stijenama zapravo ovisi o količini i raspodjeli radija i uranija. Plin radon u kristalnoj rešetci u kojoj je nastao ostaje čvrsto zarobljen, sve do svog raspada [10].

Radon je prisutan u kućama iz nekoliko izvora: zemni plin (<1 %), podzemna voda (5 %), građevinski materijal (5 – 10 %) i tlo ispod kuće (85 – 90 %). Najveća koncentracija radona prisutna je u podrumima i prizemljima zbog direktnog dodira s tlom. Koncentracija na katovima je upola manja, dok je koncentracija iznad prvog kata gotovo zanemariva. Vrlo je važna vrsta tla ispod građevine, primjerice ako se radi o tlu visoke propusnosti poput pjeskovitog tla, radonu je omogućeno lakše kretanje, čime se uzrokuje visoka koncentracija u zatvorenim prostorijama. U zatvorene prostorije može doprijeti kroz razne načine: vodovodom i kanalizacijskom infrastrukturom, kroz zemljane podove, slavine (osobito pod tušem) te spojevima na građevinama (Slika 8.) [1].

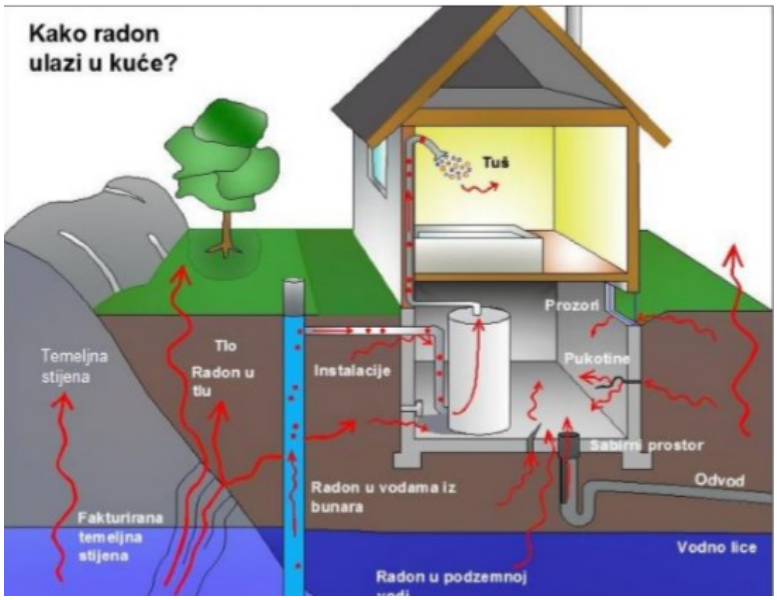

Slika 8. Način ulaska radona u kuću [11]

Istraživanjem radona prati se geogenski radonski potencijal (parametar za radiološko ispitivanje tla) na temelju procjene permeabilnosti (propusnosti) tla i koncentracije radona u tlu. Visokim geogenskim radonskim potencijalom označava se ako je vrijednost iznad 100 kBq/m^3, srednjim se označava dok je vrijednost od 30 do 100 kBq/m^3 te se vrijednosti ispod 30 kBq/m^3 označava kao niski geogenski radonski potencijal [12].

2.4. Načini mjerenja koncentracije radona

Za detekciju ionizirajućeg zračenja postoje različite tehnike i metode. U mjernim tehnikama su detektirajući „fenomeni“ alfa, beta i gama zračenje. Kada je riječ o radonu, mjerenje se može provesti direktno ili indirektno [1].

- *MJERENJE KONCENTRACIJE RADONA U TLU I ZRAKU*

Pomoću uređaja RAD7 (Slika 9.) može se izmjeriti koncentracija radona u zraku, vodi i zemlji. RAD7 uređaj se može koristiti na terenu ili u laboratoriju zahvaljujući bakterijskom napajanju i kompaktnom dizajnu. Korištenje uređaja za mjerenje koncentracije na licu mjesta, bilo da se radi o laboratoriju ili terenu, daje veliku prednost u uporabi [13].

Slika 9. Alfa spektrometar DURRIDGE RAD7 [13]

Uz mogućnost selidbe, RAD7 ima i mogućnost pohrane podataka do kraja mjerenja koji se čuvaju u internoj memoriji. Na ispisanom izvješću nalaze se slijedeće informacije: datum, vrijeme, srednja koncentracija aktivnosti radona za određeni period mjerenja,

standardna devijacija srednje koncentracije, maksimalna i minimalna izmjerena vrijednost, histogram srednjih vrijednosti [13].

- *MJERENJE KONCENTRACIJE RADONA U VODI*

Osnovni RAD7 uređaj, ali s potrebnim dodacima koristi se za mjerenje koncentracije radona u vodi (Slika 10.). RAD – H_20 metoda upotrebljava strujanje zraka pomiješanog s vodom (volumen zraka i vode su stalni) kroz zatvorenu petlju. Zrak neprekidno kruži kroz vodu i izlučuje radon te određuje koncentraciju radona isto kao i kod osnovnog rada mjernog uređaja.

Slika 10. Uređaj RAD7 s dodacima za mjerenje radona u vodi [14]

Faktori koji utječu na točnost mjerenja koncentracije radona u vodi su:

- temperatura
- relativna vlažnost
- vrijeme mjerenja
- veličina uzorka

- koncentracija uzorka
- način uzimanja uzorka.

Za mjerenje radona u vodi koncentracija manjih od 0,37 Bq/l do koncentracija većih od $0{,}15*10^5$ Bq/l omogućuje RAD7-H_20 [13].

2.5. Utjecaj radona na ljudsko zdravlje

Najveći udio zračenja koje čovjek primi iz prirodnih izvora ima radon i njegovi potomci. U protorijama gdje ljudi svakodnevno borave, povećane koncentracije radona mogu negativno utjecati na zdravlje čovjeka, primjerice povećati rizik nastanka karcinoma.

Kao što je već spomenuto, radon se apsorbira u zatvorenim prostorijama (kuće, podrum) gdje ulazi rasprostranjivanjem iz tla ili ulazi zbog tragova urana u građevinskom materijalu izravno iz zidova u prostoriju. Radon se nalazi u zraku i svakodnevno ga neizbježno udišemo te se u plućima raspada, pri čemu dolazi do velike količine oslobođene energije zbog koje se pri raspadu oštećuju stanice plućnog tkiva. No, vjerojatnost raspadanja u plućima je mala zbog dugog vremena poluživota. Kod velikih koncentracija radona ta vjerojatnost nije zanemariva, s obzirom na to da dolazi do mogućnosti izravnog raspada. Veći doprinos imaju njegovi potomci (^{218}Po, ^{214}Pb, ^{214}Bi) koji se raspadom vežu na aerosle (sitne čestice u zraku) i udisanjem dospijevaju u pluća gdje se raspadaju. Količina zračenja koja se primi od radona i njegovih potomaka zapravo ovisi o koncentraciji tih aerosoli, kao i o količini zračenja u prostoriji u kojoj se boravi. Smanjenje koncentracije radona, kao i njegovih potmaka, se vrši dobrom ventilacijom i redovitim provjetravanjem prostorija u kojima ljudi borave.

Rizik od smrtnosti uslijed raka pluća povećava se za 0,1 %, za čovjeka koji je tijekom svoga života izložen radonskom zračenju od 1 mSv/godišnje. U europskim i sjeverno američkim državama prosječna koncentracija radona iznosi 20 – 60 Bq/m^3 u zatvorenim prostorijama te boravak u takvim uvjetima povećava rizik raka pluća 0,1 – 0,5 % [15].

3. REGRESIJSKA ANALIZA

Regresijska analiza je metoda koja se bavi određivanjem funkcionalne korelacije između dviju ili više varijabli, dok je regresijski model analitički izraz te korelacije. Regresijske tehnike omogućuju kvantitativno iskazivanje takve korelacije te se dobiveni regresijski model koristi za predviđanje nekih podataka za koje ne postoje mjerenja.

Tri su slučaja regresijske analize:

- *Linearna regresija* je najjednostavniji slučaj gdje postoji linearna zavisnost jedne varijable (y) o jednoj nezavisnoj varijabli (x),
- *Višestruka regresija* gdje je moguća korelacija jedne varijable (y) o više nezavisnih varijabli,
- *Nelinearna regresija* je nelinearna zavisnost jedne varijable (y) o nezavisnoj varijabli (x).

Nezavisna varijabla je varijabla koja se određuje eksperimentalno (mjerenjem) i čiji se učinak promatra, dok je zavisna varijabla vrijednost koja ovisi o vrijednosti nezavisne varijable. Za nezavisnu varijablu se uzima fizikalna veličina koja se može najtočnije mjeriti.

Ako se pretpostavi da postoji funkcija $f(x)$ za svaku vrijednost nezavisne varijable x_i, zavisna se varijabla može pisati kao:

$$y_i = f(x_i) + e_i \tag{3.1}$$

gdje je pogreška e_i slučajna varijabla s normalnom raspodjelom i očekivanom vrijednošću 0.

Pretpostavi li se nadalje, da postoje koeficijenti a i b za svaku vrijednost nezavisne varijable x_i, zavisna se varijabla može pisati kao:

$$y_i = bx_i + a + e_i \tag{3.2}$$

gdje se koeficijenti a i b određuju metodom najmanjih kvadrata. Metoda najmanjih kvadrata minimizira vrijednosti kvadrata na udaljenosti između opaženih podataka i regresijskog pravca.

Regresijska analiza je matematički model za pronalazak krivulje koja prolazi kroz skup točaka, tako da je suma kvadratnog odstupana izmjerenih podataka i procijenjenih podataka minimalna. Kvadratno odstupanje se koristi za izbjegavanje predznaka odstupanja [16].

3.1. Linearni regresijski model

Regresijska analiza odnosi se na modeliranje relacija kako bi se istražila povezanost slučajne varijable y o jednoj ili više nezavisnih slučajnih varijabli x. Zaključak predstavlja nizu sparenih mjerenja (x_1, y_1), …, (x_n, y_n), gdje su x_1,…, x_n vrijednosti nezavisnih varijabli, a y_1,…, y_n vrijednosti zavisnih varijabli. Nezavisna varijabla za konkretne primjere često se naziva kontroliranom varijablom. Na temelju rezultata mjerenja slučajnih uzoraka sparenih mjerenja (x_1, y_1), …, (x_n, y_n) cilj je ustanoviti zavisnost slučajnih varijabli y o nezavisnim varijablama x.

Prvenstveno je potrebno definirati matematički model:

$$y_i = f(x_i) + e_i \ \ (i = 1, \dots, n) \tag{3.1}$$

gdje su: $x \to f(x)$ realna funkcija samo jedne varijable, a $e_i, \dots, e_n$ nezavisne složene varijable, takve da je $E[e_i] = 0$ i $Var(e_i) = \sigma^2$.

Najprije se prikažu podaci između varijabli x i y u dijagramu raspršenosti kako bi se moglo ustanoviti grupiraju li se točke oko pravca (u tom slučaju se može pretpostaviti da su varijable linearno zavisne) ili neke druge krivulje. Za što precizniju pretpostavku o regresijskoj funkciji, slučajne uzorke $((x_i, y_i), \dots, (x_n, y_n))$ se prikazuju točkama u koordinatnom sustavu. Pretpostavljajući da je graf funkcije $f(x)$ pravac, što znači da slučajna

varijabla y linearno ovisi o nezavisnoj varijabli x, regresijska funkcija se može zapisati u eksplicitnom obliku:

$$f(x) = \alpha + \beta x \tag{3.2}$$

Parametar β je koeficijent smjera koji se naziva koeficijent regresije, a pravac $y = \alpha + \beta x$ je regresijski pravac.

Nepoznati parametri α i β identificiraju se procjenom nepoznatog regresijskog pravca. U dijagramu raspršenosti nacrtan je pravac regresije $y = \alpha + \beta x$. Iz Slike 11. vidljivo da je za vrijednost x_i nezavisne varijable x, zavisna varijabla y_i poprimila vrijednost $\alpha + \beta x_i$.

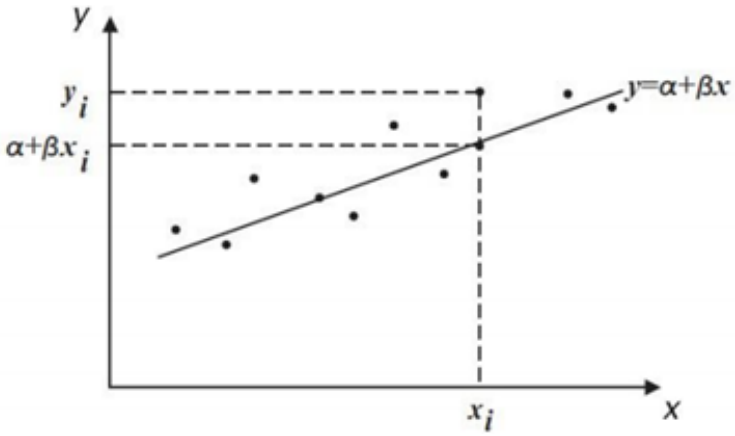

Slika 11. Dijagram raspršenja [17]

Nastoji se doznati razlika između eksperimentalnih i teorijskih vrijednosti zavisne varijable y u dijagramu točnije $d_j = y_i - (\alpha + \beta x_i)$. Regresijski parametri α i β se procjenjuju metodom najmanjih kvadrata.

Cilj metode najmanjih kvadrata je minimizacija sume kvadratnih odstupanja teoretskih vrijednosti (y_i) od eksperimentalnih vrijednosti ($\hat{\alpha} + \hat{\beta} x_i$). Procjene $\hat{\alpha}$ i $\hat{\beta}$ se određuju tako da se minimizira izraz $D(\hat{\alpha}, \hat{\beta})$.

$$D(\hat{\alpha},\hat{\beta}) = \sum_{i=1}^{n}[y_i - (\hat{\alpha} + \hat{\beta}x_i)]^2$$
$$= \min_{(\alpha,\beta)\in R^2} \sum_{i=1}^{n}[y_i - (\alpha + \beta x_i)]^2 = \min_{(\alpha,\beta)\in R^2} D(\alpha,\beta) \quad (3.3)$$

Najbolja procjena nepoznatog regresijskog pravca $y = \alpha + \beta x$ je pravac $\hat{y} = \hat{\alpha} + \hat{\beta}x$. Za dobivanje analitičkog rješenja procjene $\hat{\alpha}$ i $\hat{\beta}$ regresijskih parametara α i β potrebne su sljedeće vrijednosti: aritmetička sredine varijable x_i $[\bar{x}]$, aritmetička sredina varijable y_i $[\bar{y}]$, srednje kvadratno odstupanje varijabli x od $\bar{x}$ $[S_x^2]$, srednje kvadratno odstupanje y od $\bar{y}$ $[S_y^2]$ te uzročna kovarijanca $[S_{xy}]$. Rješavanjem sustava jednadžbe (3.3) dobije se procjena $\hat{\alpha}$ i $\hat{\beta}$ regresijskih parametara α i β u metodi najmanjih kvadrata:

$$\hat{\beta} = \frac{S_{xy}}{S_x^2}$$
$$\hat{\alpha} = \bar{y} - \beta\bar{x} \quad (3.4)$$

Iz prikazanog slijedi konačni izraz za koeficijente regresijskog pravca $y = \alpha + \beta x$ koji glasi:

$$\beta = \frac{\sum_{i=1}^{n} x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^{n} x_i^2 - n\bar{x}^2}$$
$$\alpha = \bar{y} - \beta\bar{x} \quad (3.5)$$

Pomoću formule regresijskog pravca, za svaku eksperimentalnu vrijednost x_i te za svaku teorijsku vrijednost y_i, može se izračunati koliko zapravo iznosi svako odstupanje teorijske od eksperimentalne vrijednosti:

$$\hat{e_i} = y_i - \hat{y}_i = y_i - (\hat{\alpha} + \hat{\beta}x) \quad (3.6)$$

S obzirom na to da se račun radi za svaku pojedinu vrijednost, dobije se niz odstupanja $\hat{e}_1, \dots, \hat{e}_n$, koji se naziva rezidualima, a zbroj svih kvadrata reziduala označavamo sa SSE:

$$\mathrm{SSE} = \sum_{\mathrm{i}=1}^{\mathrm{n}} [\mathrm{y_i} - (\hat{\alpha} + \hat{\beta}\mathrm{x_i})]^2 \tag{3.7}$$

Nakon ocjene parametara regresijskog modela slijedi reprezentativnost, odnosno, sposobnost modela da objasni kretanje zavisne varijable *y* uz pomoć nezavisne varijable *x*. Apsolutni i relativni pokazatelji kazuju kolika je razlika vrijednosti zavisne varijable u regresijskom modelu od njenih očekivanih vrijednosti $\hat{y}_i$ i njene aritmetičke sredine $\bar{y}$.

Manja odstupanja vrijednosti zavisne varijable od njene aritmetičke sredine prikazuje procjena varijance ili procjena pogreške koja se označava s σ^2 te se zapisuje na sljedeći način:

$$\hat{\sigma}^2 = \sqrt{\frac{1}{\mathrm{n}-2}\sum_{\mathrm{i}=1}^{\mathrm{n}} [\mathrm{y_i} - (\alpha + \beta\mathrm{x_i})]^2} = \sqrt{\frac{\mathrm{SSE}}{\mathrm{n}-2}} \tag{3.8}$$

Standardna greška ili standardna devijacija regresije je pokazatelj reprezentativnosti regresijskog modela. Ona pokazuje prosječni stupanj varijacije stvarnih vrijednosti zavisne varijable. Prethodni izraz (3.8) odnosi se na standardnu grešku regresije jednostrukog modela te je taj pokazatelj izražen u jedinicama mjere zavisne varijable i teško je uspoređivati reprezentativnost modela s različitim mjernim jedinicama. S druge strane, koeficijent varijacije eliminira taj problem i on predstavlja postotak standardne greške od aritmetičke sredine varijable *y*:

$$V = \frac{\hat{\sigma}^2}{\bar{y}} * 100\% \tag{3.9}$$

Što je koeficijent varijacije regresijskog modela manji i bliži nuli, to je model reprezentativniji. Dogovorena granica reprezentativnosti je od 30 %, što znači da se model smatra dobrim ako je koeficijent manji od 30 %.

Sljedeći pokazatelj reprezentativnosti regresijskog modela je koeficijent determinacije r^2 i on se temelji na analizi varijance. Koeficijent determinacije daje informacije koliko rasipanja izlaznih podataka potječe od funkcijske ovisnosti $x \rightarrow \alpha + \beta x$, a koliko otpada na neobjašnjeno rasipanje. Isto tako govori kolika je jaka veza između x i y. Koeficijent determinacije r^2 se računa na sljedeći način:

$$r^2 = \frac{\sum_{i=1}^{n}(\hat{y}_i - \bar{y})^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{3.10}$$

Raspon koeficijenta determinacije je u intervalu $0 \leq r^2 \leq 1$. Regresijski model je reprezentativniji što je vrijednost koeficijenta determinacije bliža 1, a zavisnost između x i y je jača [17].

3.2. Višestruki regresijski model

Višestruki regresijski model sadrži više od jedne nezavisne varijable.

Opći oblik višestrukog regresijskog modela je sljedeći:

$$y = f(x_1, x_2, x_3, \dots, x_i, \dots, x_k) x\, e \tag{3.11}$$

Zavisna varijabla je y, nezavisne varijable su $x_1, x_2, \dots, x_k$, dok varijabla e izražava nepoznata odstupanja od funkcionalnog odnosa. Ako je veza između y i $x_1, x_2, \dots, x_k$ linearna, model iz prethodnog izraza (3.11) postaje model višestruke linearne regresije:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_k x_k + e \tag{3.12}$$

U navedenom modelu nezavisne varijable su $x_1,..,x_k$, zavisna varijabla je y, e je slučajna varijabla, a β je nepoznati parametar. Ako se pretpostavi da linearna regresijska veza između zavisne varijable i odabranog skupa nezavisnih varijabli određuje na temelju veličine n, tada se može napisati sustav od n jednadžbi mjerenja odabranih varijabli :

$$\begin{aligned}
y_1 &= \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \cdots + \beta_j x_{1j} + \cdots + \beta_k x_{1k} + e_1 \\
y_2 &= \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \cdots + \beta_j x_{2j} + \cdots + \beta_k x_{2k} + e_2 \\
&\vdots \\
y_i &= \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_j x_{ij} + \cdots + \beta_k x_{ik} + e_i \\
&\vdots \\
y_n &= \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \cdots + \beta_j x_{nj} + \cdots + \beta_k x_{nk} + e_n
\end{aligned} \tag{3.13}$$

Uvrsti li se u $Y = X\beta + e$ umjesto vektora parametra β vektor procjena, tada je:

$$\begin{aligned}
Y &= X\hat{\beta} + \hat{e} \\
\hat{e} &= Y - X\hat{\beta}
\end{aligned} \tag{3.14}$$

$\hat{e}$ je rezidualno odstupanje, točnije, procjena slučajne varijable na bazi uzorka e. Procjena koeficijenta β metodom najmanjih kvadrata dobit će se tako da se minimizira suma kvadrata rezidulanog odstupanja:

$$L = \sum_{i=1}^{n} \hat{e}_i^{\,2} = \sum_{i=1}^{n} \left(y_i - \hat{\beta}_0 - \sum_{j=1}^{k} \hat{\beta}_j x_{ij}\right)^2 \rightarrow \min \tag{3.15}$$

Postoji $p = k + 1$ normalna jednadžba, za svaki nepoznati regresijski koeficijent. Rješenje normalne jednadžbe će biti procjenitelj najmanjih kvadrata regresijskog koeficijenta. Rješavanjem sustava linearnih jednadžbi mogu se riješiti normalne jednadžbe.

Postavljanje višestrukog regresijskog modela lakše je izraziti matematičkom operacijom kroz matrični zapis. Ako se pretpostavi da postoji n regresorskih varijabli i k promatranja, $i = 1,2, \ldots, n$, model koji povezuje regresore glasi:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_j x_{ij} + \cdots + \beta_k x_{ik} + e_i \quad i = 1,2,\ldots,n \tag{3.16}$$

Model sustava od *n* jednadžbi se može izraziti u matričnom zapisu kao:

$$y = \beta x + e \tag{3.17}$$

gdje je:

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix} X = \begin{bmatrix} 1 & x_{11} & x_{12} & \ldots & x_{1j} & \ldots & x_{1k} \\ 1 & x_{21} & x_{22} & \ldots & x_{2j} & \ldots & x_{2k} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{i1} & x_{i2} & \ldots & x_{ij} & \ldots & x_{ik} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & \ldots & x_{nj} & \ldots & x_{nk} \end{bmatrix} e = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_i \\ \vdots \\ e_n \end{bmatrix} \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_i \\ \vdots \\ \beta_k \end{bmatrix} \tag{3.18}$$

Kako bi se pronašao vektor procjene najmanjih kvadrata $\hat{\beta}$, vektor se dobije iz jednadžbe:

$$\frac{\partial L}{\partial \hat{\beta}} = 0 \tag{3.19}$$

Gdje je:

$$L = \sum_{i=1}^{n} \hat{e}_i^{\,2} = \hat{e}'\hat{e} = (y - X\hat{\beta})'(y - X\hat{\beta}) \tag{3.20}$$

Rješenjem derivacije (3.19) dobije se normalna jednadžba metode najmanjih kvadrata koja iznosi:

$$X'X\hat{\beta} = X'y \tag{3.21}$$

Ukoliko su slučajne varijable međusobno nezavisne, matrica X′X je invertibilna.

Iz jednadžbe metode najmanjih kvadrata (3.21) slijedi:

$$X'(y - x\hat{\beta}) = X'\hat{e} = 0 \tag{3.22}$$

odnosno da je:

$$\hat{y} = X\hat{\beta} = X(X'X)^{-1}X'y = hy \tag{3.23}$$

Dokazan je procjenitelj vektora parametara metodom najmanjih kvadrata uz hipotezu da su prethodno ispunjene sve pretpostavke o modelu.

Procjena varijance $\hat{\sigma}^2$ je važna kao i kod linearne regresije. Procjena standardne greške regresije $\hat{\sigma}^2$ kod linearnog modela dobije se dijeljenjem zbroja kvadrata reziduala sa n-2. To je tako kod jednostavne linearne regresije jer postoje samo dva parametra, dok se kod višestruke linearne regresije javlja *p* parametara, stoga je procjena varijance $\hat{\sigma}^2$ sljedeća:

$$\hat{\sigma}^2 = \frac{\mathrm{SSE}}{\mathrm{n} - \mathrm{p}} \tag{3.24}$$

Zbroj kvadrata reziduala SSE glasi:

$$\mathrm{SSE} = \sum_{\mathrm{i}=1}^{\mathrm{n}} (\mathrm{y_i} - \hat{\mathrm{y}}_\mathrm{i})^2 = \sum_{\mathrm{i}=1}^{\mathrm{n}} \mathrm{e_i}^2 = \mathrm{e}'\mathrm{e} \tag{3.25}$$

U prethodnu jednadžbu se uvrsti $\mathrm{e} = \mathrm{y} - \hat{\mathrm{y}} = \mathrm{y} - \mathrm{X}\hat{\beta}$ te se dobije formula za zbroj kvadrata reziduala SSE:

$$\mathrm{SSE} = \mathrm{y}'\mathrm{y} - \hat{\beta}'\mathrm{X}'\mathrm{y} \tag{3.26}$$

Sljedeći pokazatelj je koeficijent determinacije r^2, koji glasi:

$$\mathrm{r}^2 = \frac{\mathrm{SSR}}{\mathrm{SST}} = 1 - \frac{\mathrm{SSE}}{\mathrm{SST}} = 1 - \frac{(\mathrm{n} - \mathrm{p})\hat{\sigma}^2}{\sum_{\mathrm{i}=1}^{\mathrm{n}} (\mathrm{y_i} - \bar{\mathrm{y}})^2} \tag{3.27}$$

Pokazatelj r^2 poprima vrijednosti u intervalu $0 \leq r^2 \leq 1$, a promatrani model je reprezentativniji ako je koeficijent determinacije bliži jedinici. Prethodni izraz (3.27) ima nedostatak jer je nepristran. Ako je populacijski koeficijent determinacije jednak nuli, tada je očekivana vrijednost r^2 različita od nule. Koeficijent determinacije je veći ako je veći broj uključenih regresijskih varijabli. Nepristrana procjena varijance varijable *y* iznosi:

$$\hat{\sigma}_y^2 = \frac{\sum_{i=1}^{n}(y_i - \bar{y})^2}{n-1} \tag{3.28}$$

Korigirani koeficijent determinacije $\bar{r}^2$ koristi se kao jedan od mogućih kriterija za izbor kod višestrukog regresijskog modela. Najbolji je onaj model s najvećim $\bar{r}^2$. Izraz za korigirani koeficijent determinacije koji glasi [17]:

$$\bar{r}^2 = 1 - \frac{n-1}{n-p}(1-r^2) = 1 - \frac{n-1}{n-p}\frac{SSE}{SST} = 1 - \frac{\hat{\sigma}^2}{\hat{\sigma}_y^2} \tag{3.29}$$

3.3. Nelinearni regresijski model

Kada funkcionalni odnos između zavisne varijable *y* i nezavisne varijable *x* ne može biti aproksimiran linearnim odnosom, to jest, kada je nelinearan, tada se može koristiti polinomna regresija.

S jednom nezavisnom varijablom model polinomne regresije drugog stupnja glasi:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \cdots + \beta_k x^k + e \tag{3.30}$$

Kao i kod jednostavne linearne regresije i višestrukog regresijskog modela, *y* je zavisna varijabla, *x* je nezavisna varijabla, $\beta_1, \beta_2, \ldots, \beta_k$ su nepoznati parametri koje je potrebno procijeniti, a *e* je slučajna varijabla. Nepoznati parametri dobiju se procjenom i to metodom najmanjih kvadrata:

$$L = \sum_{i=1}^{n}(y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i - \hat{\beta}_2 x_i^2 - \cdots - \hat{\beta}_k x_i^k)^2 \rightarrow \min \tag{3.31}$$

gdje su $\hat{\beta}_0, \hat{\beta}_1, \ldots, \hat{\beta}_k$ procjena parametara $\beta_0, \beta_1, \ldots, \beta_k$. Točka u kojoj funkcija dostiže svoj minimum dobiva se izjednačavanjem njene parcijalna derivacija s nulom te rješavanjem sljedeće jednadžbe:

$$\frac{\partial \mathrm{L}}{\partial \hat{\beta}} = 0 \tag{3.32}$$

Pojednostavljenjem prethodnog izraza (3.32), dobiva se jednadžba metode najmanjih kvadrata:

$$\begin{gathered}
n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^{n} x_i + \hat{\beta}_2 \sum_{i=1}^{n} x_i^2 + \cdots + \hat{\beta}_k \sum_{i=1}^{n} x_i^k = \sum_{i=1}^{n} y_i \\
\hat{\beta}_0 \sum_{i=1}^{n} x_i + \hat{\beta}_1 \sum_{i=1}^{n} x_i^2 + \hat{\beta}_2 \sum_{i=1}^{n} x_i^3 + \cdots + \hat{\beta}_k \sum_{i=1}^{n} x_i^{k+1} = \sum_{i=1}^{n} x_i y_i \\
\hat{\beta}_0 \sum_{i=1}^{n} x_i^2 + \hat{\beta}_1 \sum_{i=1}^{n} x_i^3 + \cdots + \hat{\beta}_k \sum_{i=1}^{n} x_i^{k+2} = \sum_{i=1}^{n} x_i^2 y_i \\
\hat{\beta}_0 \sum_{i=1}^{n} x_i^k + \hat{\beta}_1 \sum_{i=1}^{n} x_i^{k+1} + \cdots + \hat{\beta}_k \sum_{i=1}^{n} x_i^{2k} = \sum_{i=1}^{n} x_i^k y_i
\end{gathered} \tag{3.33}$$

Za svaki od nepoznatih regresijskih koeficijenata postoje $k + 1$ normalna jednadžba, a rješavanjem normalne jednadžbe dobije se procjenitelje najmanjih kvadrata regresijskih koeficijenata [17].

4. EKSPERIMENTALNI DIO

4.1. Opis lokacija

Mjerenje koncentracije radona provedeno je na 8 lokacija na području Varaždinske i Koprivničko – križevačke županije (sjeverozapadna Hrvatska),Slika 12.

Slika 12. Karta lokacija mjerenja

Popis lokacija prema brojevima:

Lokacija 1 – Donje Ladanje (Varaždinska županija)
Lokacija 2 – Beletinec (Varaždinska županija)
Lokacija 3 – Vinica (Varaždinska županija)
Lokacija 4 – Varaždin (Varaždinska županija)
Lokacija 5 – Ludbreg (Varaždinska županija)
Lokacija 6 – Lukovec (Koprivničko – križevačka županija)
Lokacija 7 – Koprivnica (Koprivničko – križevačka županija)
Lokacija 8 – Herešin (Koprivničko – križevačka županija)

4.2. Mjerenje koncentracije radona

Mjerenja koncentracije radona provedena su mjernim instrumentom Airthings Corentium Pro (Slika 13.). Corentium Pro sadrži četiri radonske komore koje rade paralelno u svrhu dobivanja što preciznijih i točnijih rezultata. Princip rada je slijedeći: uređaj uzrokuje zrak u zatvorenom prostoru kroz pasivnu difuzijsku komoru te precizno izračunava razinu radona koristeći alfa spektrometriju. Radon se identificira silicijskim fotodiodama za mjerenje energije i brojanje α čestica koje su proizašle iz raspadajućeg lanca radona. Mjerni instrument je kalibriran za referentne instrumente u akreditiranim laboratorijima i ima AARST-NRPP certifikat (certifikat Američkog udruženja tehnologa i znanstvenika koji proučavaju radon). Osim četiri radonske komore, instrument posjeduje i senzore za mjerenje temperature, tlaka i vlažnosti zraka. Prednost ovog uređaja je što je lagan i lako prenosiv te nisu potrebni kablovi ni periferne jedinice [18].

Slika 13. Uređaj Corentium Pro [19]

5. REZULTATI I RASPRAVA

5.1. Prikaz podataka dobivenih mjerenjima

Na mjernim lokacijama izmjerene su vrijednosti koncentracije radona, temperature, vlažnosti i atmosferskog tlaka. U tablicama od 1 do 4 prikazane su vrijednosti pojedinih izmjerenih parametara. U Tablici 1. prikazane su minimalne, maksimalne i prosječne vrijednosti koncentracije radona te je vidljivo da je koncentracija radona manja u prizemlju i na prvom katu u odnosu na podrumske prostorije. Vrijednosti koncentracije radona dobivene na lokaciji 7. pokazuje odstupanje od ostalih mjerenja te je moguće pretpostaviti da podrumske prostorije navedene lokacije imaju dobru ventilaciju te je koncentracija radona znatno manja u odnosu na prizemlje.

Tablica 1. Vrijednosti koncentracije radona (min., max. i prosječna)

NAZIV LOKACIJE	c_{MIN} [Bq/m^3]	c_{MAX} [Bq/m^3]	c_{sr} [Bq/m^3]
LOKACIJA 1 – podrum	9	123	46,2
LOKACIJA 1 – prizemlje	9	72	21,7
LOKACIJA 2 – podrum	2,17	207	70
LOKACIJA 3 – prizemlje	1,85	232	56
LOKACIJA 4 – 1.kat	0,54	154	52,2
LOKACIJA 5 – 1.kat	2,95	363	132
LOKACIJA 6 – podrum	2,49	220	83
LOKACIJA 7 – podrum	1,35	68	16
LOKACIJA 7 – prizemlje	0,89	112	36
LOKACIJA 8 – podrum	1,45	262	87
LOKACIJA 8 – 1.kat	0,8	112	36

U Tablici 2. prikazane su temperaturne vrijednosti za pojedine lokacije. Iz rezultata je vidljivo da su vrijednosti temperature u podrumskim prostorijama i prizemlju otprilike jednake na većini lokacija, ako se promatraju srednje izmjerene temperature, osim na lokaciji 8., gdje je znatna razlika u prosječnim izmjerenim vrijednostima. Za pretpostaviti je

da su odstupanja prisutna zbog mjerenja tijekom zimskih mjeseci kada je povećano zagrijavanje prostorija u kojima ljudi borave.

Tablica 2. Vrijednosti temperature (min., max. i prosječna)

NAZIV LOKACIJE	T_{MIN} [°C]	T_{MAX} [°C]	Tsr [°C]
LOKACIJA 1 – podrum	21	24,6	22,5
LOKACIJA 1 – prizemlje	21	23,6	22,8
LOKACIJA 2 – podrum	21,4	24,4	23,6
LOKACIJA 3 – prizemlje	18,3	26,8	23,6
LOKACIJA 4 – 1.kat	24,9	30,6	27,3
LOKACIJA 5 – 1.kat	17,4	26,2	20,4
LOKACIJA 6 – podrum	14,6	19,4	16,1
LOKACIJA 7 – podrum	15	19,4	16,9
LOKACIJA 7 – prizemlje	19,8	30,2	25,1
LOKACIJA 8 – podrum	15,2	19,2	16,8
LOKACIJA 8 – 1.kat	14,2	19,2	16,8

U Tablici 3. prikazani su rezultati minimalnih, maksimalnih i prosječnih vrijednosti parametara vlažnosti. Izmjerene vrijednosti okolišnog parametra vlažnosti kreću se od 39 – 75 %, ovisno o lokaciji te o periodu godine.

Usporede li se vrijednosti iz Tablica 1 i 3, vidljivo je da je koncentracija radona viša ukoliko je vlažnost niža, ali samo u slučajevima mjerenja u podrumskim prostorijama i prizemlju.

Tablica 3. Vrijednosti okolišnog parametra vlažnosti (min., max. i prosječna)

NAZIV LOKACIJE	H_{MIN} [%]	H_{MAX} [%]	Hsr [%]
LOKACIJA 1 – podrum	39,9	52,2	44,3
LOKACIJA 1 – prizemlje	55,8	62,1	59,4
LOKACIJA 2 – podrum	32	47	39
LOKACIJA 3 – prizemlje	44	86,9	53
LOKACIJA 4 – 1.kat	46	61,9	53,8
LOKACIJA 5 – 1.kat	41	62	54
LOKACIJA 6 – podrum	50	96	75
LOKACIJA 7 – podrum	43	60	52
LOKACIJA 7 – prizemlje	33	52	41
LOKACIJA 8 – podrum	48	67	62
LOKACIJA 8 – 1.kat	43	64	55

U Tablici 4. navedene su minimalne, maksimalne i prosječne vrijednosti atmosferskog tlaka. Vrijednosti atmosferskog tlaka općenito ovise o nadmorskoj visini, a što je ona viša, tlak je niži. Vrijednosti izmjerenog atmosferskog tlaka na pojedinim lokacijama kreću se od 98 do 102 kPa Iz rezultata je vidljivo da je koncentracija radona viša na lokacijama gdje je izmjerena najniža vrijednost atmosferskog tlaka (tablica 1 i 4).

Naime, na lokaciji 5. prosječna izmjerena koncentracija radona iznosila je 132 Bq/m^3, a prosječna vlažnost zraka 99,96 kPa.

Tablica 4. Vrijednosti atmosferskog tlaka (min., max. i prosječna)

NAZIV LOKACIJE	p_{MIN} [kPa]	p_{MAX} [kPa]	p_{sr} [kPa]
LOKACIJA 1 – podrum	98,57	100,51	99,21
LOKACIJA 1 – prizemlje	98,61	99,41	99,08
LOKACIJA 2 – podrum	98,44	101,06	99,69
LOKACIJA 3 – prizemlje	98,34	100,6	99,53
LOKACIJA 4 – 1.kat	97,46	99,74	98,73
LOKACIJA 5 – 1.kat	98	101,23	99,96
LOKACIJA 6 – podrum	98,37	100,14	99,16
LOKACIJA 7 – podrum	96,83	100,66	98,9
LOKACIJA 7 – prizemlje	100,5	102,09	101,36
LOKACIJA 8 – podrum	99,54	101,32	100,48
LOKACIJA 8 – 1.kat	99,69	101,8	100,67

5.2. Uspostava višestrukog linearnog regresijskog modela

Temeljem izmjerenih vrijednosti koncentracije radona i okolišnih parametara (temperatura, vlažnost, atmosferski tlak) određena je statistička povezanost između navedenih pokazatelja. Drugim riječima, pokušalo se odrediti postoji li povezanost između koncentracije radona i okolišnih parametara. Pomoću jednostavnog modela regresijske tehnike ustanovljena je korelacija (ovisnost) između koncentracije radona i okolišnog parametra. Korištena je tehnika određivanja koeficijenta korelacije između dviju veličina, odnosno između koncentracije radona i svakog pojedinog okolišnog parametra [20]. Na slikama 14. i 15. prikazani su dijagrami raspršenja za koncentraciju radona i pojedine okolišne parametre (vlažnost i tlak) te je ucrtan pravac regresije s naznačenim izračunatim Pearsonovim koeficijentom korelacije. Na Slici 14. prikazan je dijagram raspršenja za odnos koncentracije radona i parametra vlažnosti na lokaciji 6 – podrum, s izračunatim padajućim Pearsonov koeficijentom korelacije koji iznosi -0,12 i ucrtanim pravcem regresije koji je padajući. U slučajevima povezanosti koncentracije radona i parametara vlažnosti dobiveni

koeficijenti korelacije su negativni te je uočena negativna korelacija između koncentracije radona i okolišnog parametra vlažnosti.

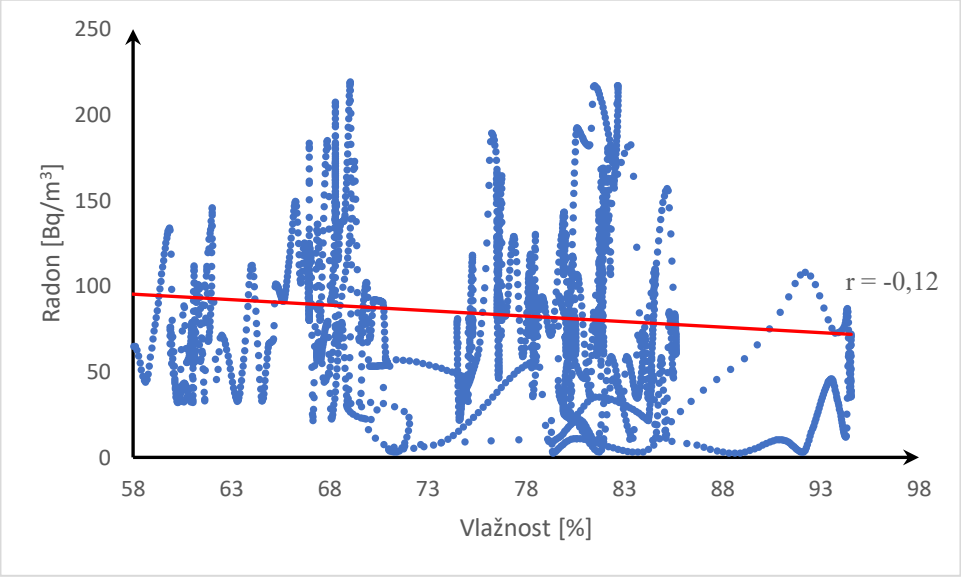

Slika 14. Dijagram raspršenja vlažnost – koncentracija radona

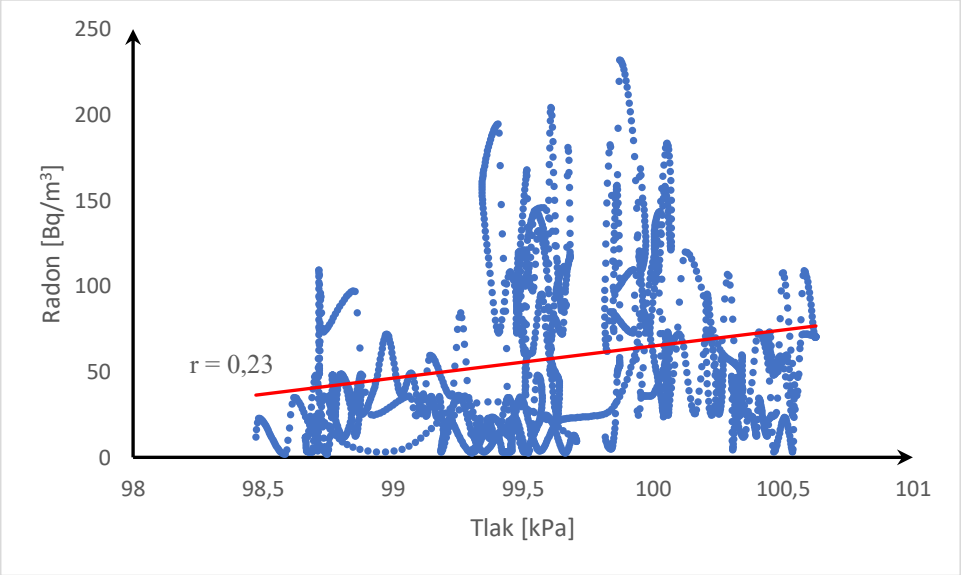

Slika 15. Dijagram raspršenja tlak – koncentracija radona

Odnos koncentracije radona i tlaka za lokaciju 3, vikendica – prizemlje prikazan je na slici 15., dijagramom raspršenja s izračunatim pripadajućim koeficijentom korelacije i

ucrtanim rastućim pravcem regresije. Pearsonov koeficijent korelacije je pozitivan i iznosi 0,23 te je i korelacija između koncentracije radona i tlaka pozitivna. Iz navedenih odnosa može se zaključiti da postoji proporcionalna povezanost između visine tlaka zraka i koncentracije radona, odnosno što je tlak zraka viši, viša je koncentracija radona.

U tablici 5 prikazane su vrijednosti svih korelacijskih koeficijenata između koncentracije radona i okolišnih parametara (temperatura, vlažnost i atmosferski tlak) na pojedinim lokacijama.

Tablica 5. Korelacijski koeficijenti koncentracije radona i okolišnih parametara

Koncentracija radona	Temperatura [°C]	Vlažnost [%]	Tlak [kPa]
LOKACIJA 1 – podrum	0,23	-0,17	0,11
LOKACIJA 1 – prizemlje	0,13	-0,05	0,23
LOKACIJA 2 – podrum	**-0,32**	0,16	**-0,30**
LOKACIJA 3 – prizemlje	**0,33**	**-0,35**	0,23
LOKACIJA 4 – 1.kat	0,03	0,05	**-0,34**
LOKACIJA 5 – 1.kat	-0,17	**0,43**	-0,03
LOKACIJA 6 – podrum	-0,08	-0,12	**-0,26**
LOKACIJA 7 – podrum	0,11	0,23	0,11
LOKACIJA 7 – prizemlje	-0,17	**0,28**	-0,20
LOKACIJA 8 – podrum	0,19	0,21	**-0,37**
LOKACIJA 8 – 1.kat	-0,08	**0,38**	**-0,27**

Budući da su svi izračunati koeficijenti korelacije po apsolutnoj vrijednosti manji od 0,5; u svim međusobnim odnosima koncentracije radona i okolišnih parametara utvrđena je slaba korelacija. U ovakvoj situaciji uputno je za svaku koncentraciju radona uzeti one okolišne parametre za koje je $|r| \geq 0{,}25$, odnosno koji na njih imaju značajniji utjecaj. Iz tog su razloga navedeni pokazatelji uzeti kao nezavisne veličine u višestrukoj regresijskoj analizi [20].

Na lokaciji 1. nema značajnijeg utjecaja okolišnih parametara na koncentraciju radona, točnije, koeficijenti korelacije po apsolutnoj vrijednosti manji su od 0,25. Na lokaciji 2., značajniji utjecaj na koncentraciju radona imaju temperatura (r = -0,32) i atmosferski tlak (r = -0,30). Značajni utjecaj temperature (r = 0,33) i vlažnosti (r = -0,35) na koncentraciju radona dobiven je korelacijskom analizom na lokaciji 3. Korelacijskom analizom je utvrđen i značajan utjecaj atmosferskog tlaka na koncentraciju radona na lokaciji 4., pri čemu je r = -0,34. Izračunat je i značajan utjecaj okolišnog parametra vlažnosti zraka na koncentraciju radona na lokaciji 6. (r = 0,43), dok je utjecaj tlaka na koncentraciju radona na istoj lokaciji izuzetno nizak (r = 0,03), za razliku od zabilježenog utjecaja tlaka na lokaciji 6. (r = -0,26). Zanimljivo je uočiti da u podrumu na lokaciji 7. nema značajnijeg utjecaja okolišnih parametara na koncentraciju radona, ali je u prizemlju zabilježen utjecaj vlažnosti zraka (r = 0,28). Na lokaciji 8. zabilježen je značajniji utjecaj atmosferskog tlaka u podrumu (r = -0,37) i na prvom katu (r = -0,27). Također, na prvom katu vidljiv je utjecaj vlažnosti (r = 0,38) na koncentraciju radona.

Općenito, nastojalo se formulirati model višestruke linearne regresije oblika prema jednadžbi

$$y = a_1x_1 + a_2x_2 + \cdots + a_nx_n \tag{5.1}$$

gdje je y koncentracija radona, x_1, …, x_n su izabrane nezavisne varijable (okolišni parametri koji imaju značajniji utjecaj na koncentraciju radona) [20].

Za primjenu modela višestruke linearne regresije uzete su obzir 3 lokacije, a to su: Beletinec (kuća za odmor) – lokacija 2., Vinica (vikendica) – lokacija 3. i Herešin (obiteljska kuća, prvi kat) – lokacija 8., budući da su na navedenim lokacijama apsolutne vrijednosti koeficijenata korelacije veće od 0,25. Drugim riječima, na ovim lokacijama statistički je značajan utjecaj određenih okolišnih parametara na koncentraciju radona. Uz jednadžbe modela višestruke regresije, prikazani su i dijagrami raspršenosti.

5.2.1. Model višestruke regresije – lokacija Beletinec

Za lokaciju 2. dobiven je sljedeći model višestruke regresije, jednadžba (5.2):

$$y = 1221{,}78 - 8{,}62 * T - 9{,}53 * p \tag{5.2}$$

gdje je *T* vrijednost okolišnog parametra temperature, a *p* vrijednost okolišnog parametra atmosferskog tlaka. Iz dobivenog modela vidljivo je da je vrijednost koncentracije radona (*y*) obrnuto proporcionalna vrijednostima okolišnih parametara temperature i tlaka. Drugim riječima, što je veća vrijednost temperature i tlaka, to će biti manja koncentracija radona u zraku. Navedeni zaključak potvrđuju i negativni predznaci ispred okolišnih parametara temperature i tlaka. Nadalje, dobivene rezultate potvrđuju i padajući pravci (Slike 16. i 17.), koji potvrđuju obrnutu proporcionalnost koncentracije radona i temperature, odnosno koncentracije radona i tlaka.

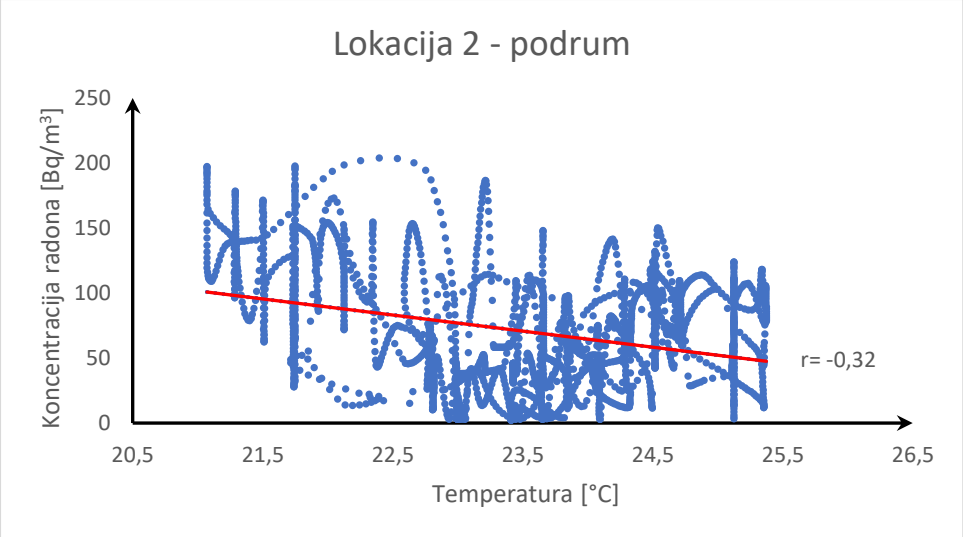

Slika 16. Dijagram raspršenosti sa ucrtanim pravcem regresije između koncentracije radona i temperature

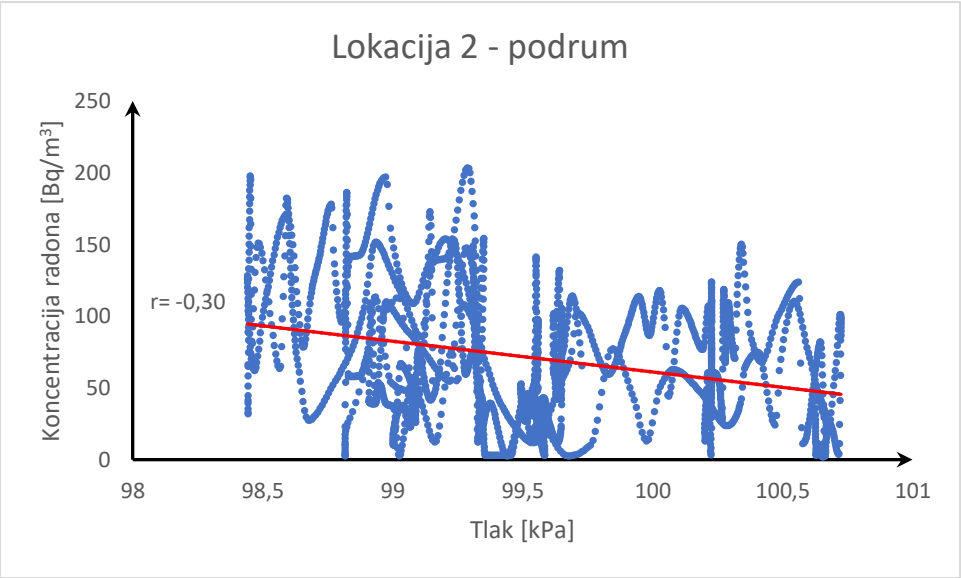

Slika 17. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i tlaka

5.2.2. Model višestruke regresije – lokacija Vinica

Za mjernu lokaciju 3. dobiven je sljedeći model višestruke regresije, jednadžba (5.3):

$$y = 63{,}11 + 1{,}85 * T - 0{,}93 * H \tag{5.3}$$

gdje je *T* vrijednost okolišnog parametra temperature, a *H* je vrijednost okolišnog parametra vlažnosti. Iz ovog je modela vidljivo da je vrijednost koncentracije radona (*y*) proporcionalna vrijednosti okolišnog parametra temperature te obrnuto proporcionalna vrijednosti okolišnog parametra vlažnosti. Navedeno upućuje da s porastom vrijednosti temperature, raste koncentracija radona u zraku. Suprotno tome, što je veća vrijednost parametra vlažnosti, to će biti manja koncentracija radona u zraku. Navedeno potvrđuju rezultati na slikama 19. i 20., gdje su vidljivi jedan rastući pravac i jedan padajući pravac. U jednostrukom modelu dobivena je pozitivna korelacija u odnosu koncentracija radona i temperature, dok je u odnosu koncentracije radona i vlažnosti korelacija negativna, što potvrđuje i negativni predznak ispred parametra *H*.

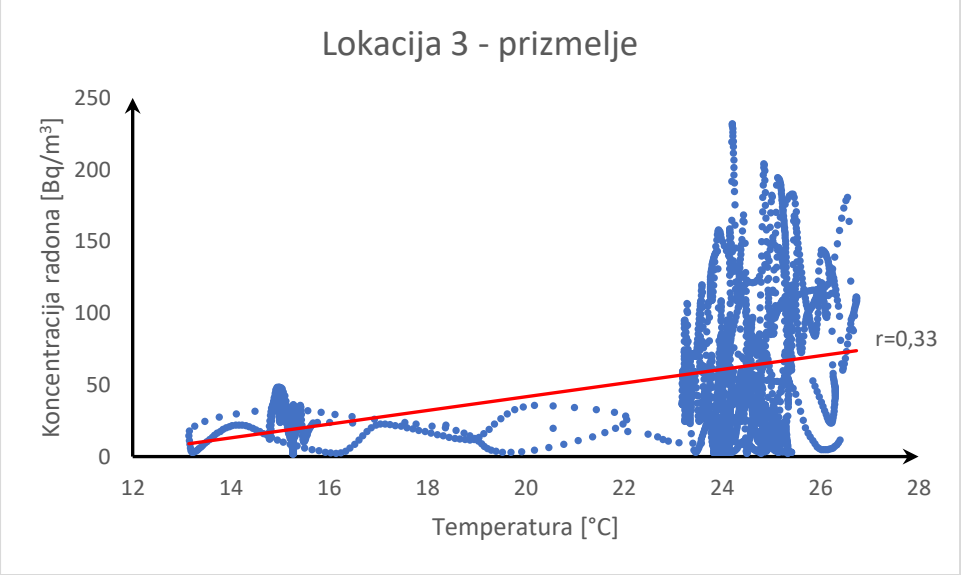

Slika 19. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i temperature

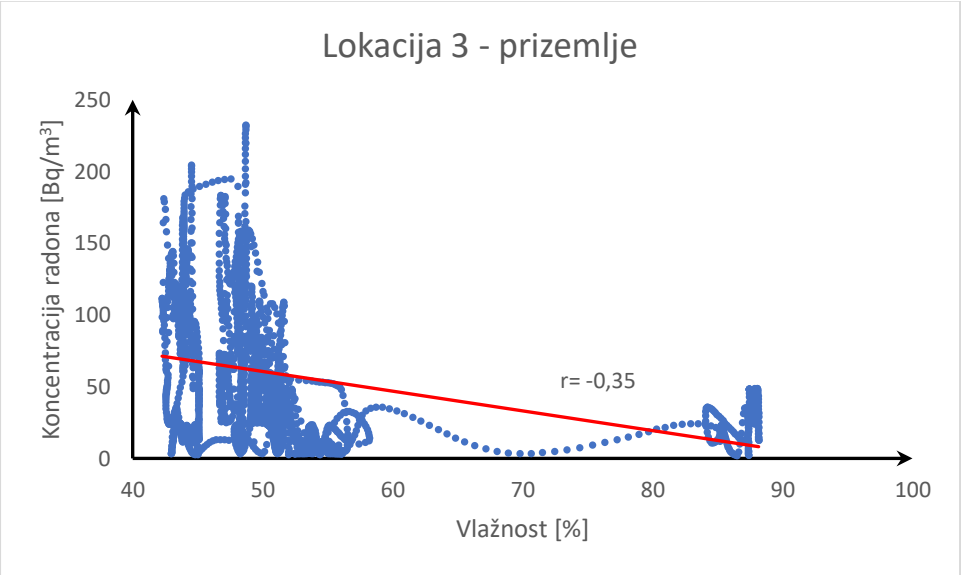

Slika 20. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i vlažnosti

5.2.3. Model višestruke regresije – lokacija Herešin

Za mjernu lokaciju 8., prvi kat dobiven je sljedeći model višestruke regresije, jednadžba (5.4):

$$y = 297{,}38 + 2{,}27 * H - 3{,}79 * p \quad (5.4)$$

gdje je *H* vrijednost okolišnog parametra vlažnosti, a *p* je vrijednost okolišnog parametra atmosferskog tlaka. Iz ovog modela vidljivo da je vrijednost koncentracije radona (y) proporcionalna vrijednosti vlažnosti, odnosno s porastom vlažnosti raste i koncentracija radona. No, koncentracija radona je obrnuto proporcionalna vrijednosti atmosferskog tlaka te s porastom atmosferskog tlaka pada koncentracija radona u zraku. Promatrajući jednostruki model regresije (Slika 21. i Slika 22.), vidljivo je da je korelacijski koeficijent pozitivan i to potvrđuje pozitivni predznak ispred vrijednosti parametra vlažnosti. No, na Slici 22. korelacijski koeficijent je negativan što potvrđuje negativni predznak ispred parametra atmosferskog tlaka.

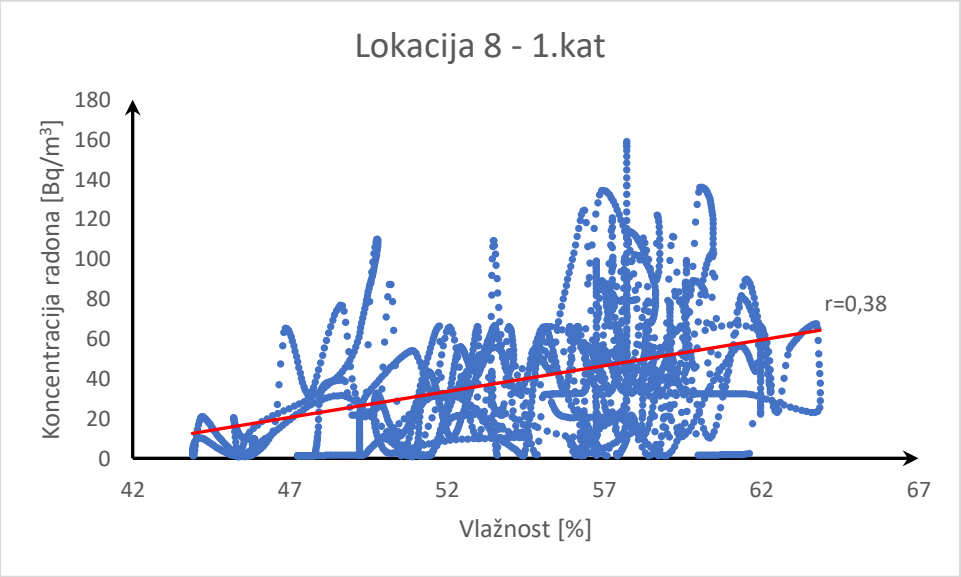

Slika 21. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i vlažnosti

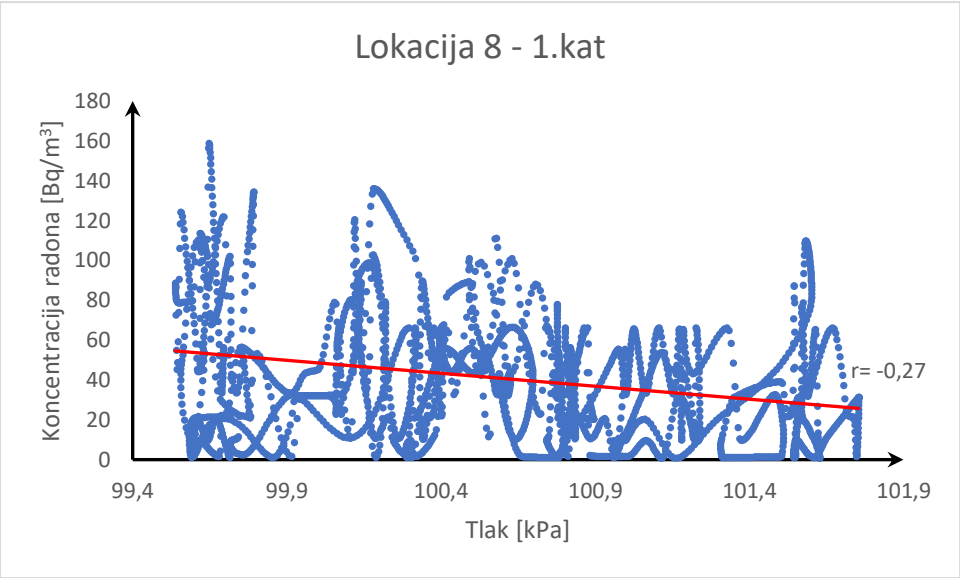

Slika 22. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i tlaka

Dobiveni modeli mogu se koristiti u svrhu predviđanja koncentracija radona na pojedinim lokacijama što znači da se iz navedenih jednadžbi za zadane vrijednosti ulaznih (nezavisnih) varijabli, može izračunati odnosno predvidjeti koncentracija radona na pojedinoj lokaciji [20].

Na lokaciji 2. ako parametar *T* iznosi 24 °C, a parametar *p* 100 kPa, koncentracija radona iznositi će 61,9 Bq/m^3, što je vidljivo iz jednadžbe 5.5 gdje su uvrštene vrijednosti parametara u jednadžbu (5.2):

$$\begin{aligned} y &= 1221{,}78 - 8{,}62 * T - 9{,}53 * p \\ y &= 1221{,}78 - 8{,}62 * 24 - 9{,}53 * 100 \\ y &= 1221{,}78 - 206{,}88 - 953 \\ y &= 61{,}9 \end{aligned} \tag{5.5}$$

Isto tako, može se izračunati koncentracija radona za lokaciju 3. pomoću jednadžbe (5.3). Uzme li se u obzir da vrijednost T iznosi 23 °C, a da je vrijednost H (vlažnost) 53 %, dobije se vrijednost koncentracije radona koja iznosi 56,37 Bq/m^3, a postupak dobivanja koncentracije radona vidi se u jednadžbi (5.6):

$$\begin{gathered} y = 63{,}11 + 1{,}85 * T - 0{,}93 * H \\ y = 63{,}11 + 1{,}85 * 23 - 0{,}93 * 53 \\ y = 63{,}11 + 42{,}55 - 49{,}29 \\ y = 56{,}37 \end{gathered} \tag{5.6}$$

Ako na lokaciji 8 na 1.katu parametar vlažnosti iznosi 55 %, a atmosferski tlak iznosi 100,87 kPa tada se uzima u obzir jednadžba (5.4) višestrukog modela. Kao rezultat dobije se vrijednost koncentracije radona koja iznosi 39,93 Bq/m^3, jednadžba (5.7):

$$\begin{gathered} y = 297{,}38 + 2{,}27 * H - 3{,}79 * p \\ y = 297{,}38 + 2{,}27 * 55 - 3{,}79 * 100{,}87 \\ y = 297{,}38 + 124{,}85 - 382{,}297 \\ y = 39{,}93 \end{gathered} \tag{5.7}$$

6. ZAKLJUČAK

Radon kao radioaktivni element najviše doprinosi prirodnom zračenju na Zemlji. Na otvorenom prostoru, koncentracije radona su niske i neopasne za ljudsko zdravlje, dok u zatvorenim prostorijama znaju biti povišene te kao takve i opasne za ljudsko zdravlje [9] . U Republici Hrvatskoj, odnosno u Varaždinskoj i Koprivničko – križevačkoj županiji, na mjernim lokacijama, većina kućanstava nije izložena previsokim vrijednostima koncentracije radona. S obzirom da najviše radona dolazi iz temeljenog tla, najviše koncentracije radona su izmjerene u podrumskim prostorijama. Primjenom korelacijske analize i uspostavom matematičkog modela moguće je utvrditi statističku povezanost između pojedinih okolišnih parametra i koncentracije radona [2]. Za uspostavu višestrukog linearnog regresijskog znatno pomaže i jednostruki model te dobiveni korelacijski koeficijent. Primjerice, ako je izračunati koeficijent korelacije za određene parametre u je jednostrukom modelu koeficijent korelacije negativan, model višestruke regresije će pokazati obrnutu proporcionalnost koncentracije radona s vrijednosti određenog okolišnog parametra. Rezultati ukazuju na različite povezanosti koncentracije radona s temperaturom, vlažnosti i atmosferskim tlakom na pojedinim mjernim lokacijama. Na svim lokacijama na kojima je koeficijent korelacije između koncentracije radona i atmosferskog tlaka po apsolutnoj vrijednosti veći od 0,25 postoji negativna koreliranost između te dvije veličine, odnosno koncentracija radona opada s povećanjem atmosferskog tlaka. S obzirom na promjenu klimatskih uvjeta na mjernim lokacijama, potrebno je uzeti u obzir dulji vremenski period kako bi se sa sigurnošću mogao utvrditi matematički model koji bi dao što precizniju predikciju ovisnosti koncentracije radona o okolišnim parametrima čime je moguće utjecati na zdravlje ljudi i podizanje kvalitete života [2].

7. LITERATURA

[1] Pejak I., Prisutnost radona u okolišu i utjecaj na ljudsko zdravlje/ završni rad; Varaždin, Geotehnički fakultet, 2018.

[2] Ptiček Siročić A., Kovač S., Hajdinjak A.: Korelacijska analiza pokazatelja kakvoće vode jezera Matičnjak./ stručni članak, 2018., 203 – 210

[3] Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2018_12_118_2380.html. Datum pristupa: 3.07.2020.

[4] Radioaktivnost. Dostupno na: https://www.fzsri.uniri.hr/files/FAKULTET/KATEDRE/Katedra_temeljne/Microsoft%20Word%20-%20Radioaktivnost_Primjena%20u%20medicini_povjerenstvo_Z.pdf. Datum pristupa: 6.04.2020.

[5] Radioaktivni otpad. Dostupno na: https://radioaktivniotpad.org/radioaktivnost/. Datum pristupa: 8.04.2020.

[6] Zračenje. Dostupno na: https://ldap.zvu.hr/~msusak/Zracenje%20i%20radioaktivnost_web_objava.pdf. Datum pristupa: 9.04.2020.

[7] Krauskopf Konard B., Beiser Arthur (2017). The physical universe. 298 – 301

[8] Slika spektar elektromagnetskog zračenja: http://www.megon.net/docs/1_tko_to_tamo_zraci/osnove_o_zracenju.htm. Datum pristupa: 6.04.2020.

[9] Trojko T. (2019). Mjerenje koncentracije radona na području sjeverozapadne Hrvatske/ diplomski rad; Varaždin, Geotehnički fakultet.

[10] Radon. Dostupno na: http://radon.dzrns.hr/o-radonu/. Datum pristupa: 15.04.2020.

[11] Slika način ulaska radona u kuću. Dostupno na: https://www.quebec.ca/en/homes-and-housing/healthy-living-environment/residential-radon/. Datum pristupa: 17.04.2020.

[12] Kemski, J., Siehl, A., Stegemann, R., Valdivia-Manchego M. (2001). Mapping the geogenic radon potential in Germany. The Science of the Total Environment. 272, 217-230.

[13] Dostupno na: https://durridge.com/documentation/RAD7%20Manual.pdf. Datum pristupa: 18.04.2020.

[14] Slika uređaj RAD7 s dodacima za mjerenje radona u vodi. Dostupno na: https://durridge.com/products/rad-h2o/. Datum pristupa: 18.04.2020.

[15] James, A. Lung Dosimetry, Nazaroff, W., Nero, Jr. (1988). Radon and its decay products in indoor air: An Overview. New York: John Wiley & Sons, Inc. 259-304.

[16] Dostupno na: https://www.pmf.unizg.hr/_download/repository/PREDAVANJE11.pdf. Datum pristupa: 27.04.2020.

[17] Lulić I. (2014). Uporaba metode regresijske analize u rješavanju problema vezanih za inženjersku praksu./ završni rad; Zagreb, Fakultet strojarstva i brodogradnje.

[18] Dostupno na: https://www.airthings.com/en/pro. Datum pristupa: 11.05.2020.

[19] Slika Uređaj Corentium Pro. Dostupno na: https://www.radonshop.com/Airhtings-Corentium-PRO-Radon. Datum pristupa: 11.05.2020.

POPIS SLIKA I TABLICA

POPIS SLIKA

Slika 1. Prodornost α, β i γ zračenja 3

Slika 2. Raspad radija-226.....4

Slika 3. β-minus raspad.....5

Slika 4. γ-raspad.....5

Slika 5. Krivulja radioaktivnog raspada i vremena poluraspada jezgre atoma.....7

Slika 6. Spektar elektromagnetskog zračenja 8

Slika 7. Izvori radijacije na Zemlji 9

Slika 8. Način ulaska radona u kuću.....10

Slika 9. Alfa spektrometar DURRIDGE RAD7 11

Slika 10. Uređaj RAD7 s dodacima za mjerenje radona u vodi 12

Slika 12. Karta lokacija mjerenja.....25

Slika 14. Dijagram raspršenja vlažnost – koncentracija radona 31

Slika 15. Dijagram raspršenja tlak – koncentracija radona.....31

Slika 16. Dijagram raspršenosti sa ucrtanim pravcem regresije između koncentracije radona i temperature 34

Slika 17. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i tlaka 35

Slika 19. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i temperature 36

Slika 20. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i vlažnosti 36

Slika 21. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i vlažnosti 37

Slika 22. Dijagram raspršenosti s ucrtanim pravcem regresije između koncentracije radona i tlaka 38

POPIS TABLICA

Tablica 1. Vrijednosti koncentracije radona (min., max. i prosječna) 27

Tablica 2. Vrijednosti temperature (min., max. i prosječna) 28

Tablica 3. Vrijednosti okolišnog parametra vlažnosti (min., max. i prosječna) 29

Tablica 4. Vrijednosti atmosferskog tlaka (min., max. i prosječna) 30

Tablica 5. Korelacijski koeficijenti koncentracije radona i okolišnih parametara 32