

doi: [10.46793/HSE-K-26.24](https://doi.org/10.46793/HSE-K-26.24)

PRIMJENA DIGITALNIH TEHNOLOGIJA (IOT SENZORI I AI ANALITIKA) U PRAĆENJU I PREVENCIJI PSIHOSOCIJALNIH RIZIKA NA RADNOM MJESTU

APPLICATION OF DIGITAL TECHNOLOGIES (IoT SENSORS AND AI ANALYTICS) IN MONITORING AND PREVENTION OF PSYCHOSOCIAL RISKS IN THE WORKPLACE

Miliša Todorović, Fakultet za tehničke studije, Univerzitet Travnik, BiH, ORCID broj: 0000-0001-6239-4285milisa.todorovic@eftfts.edu.ba,

Snežana Živković, Fakultet zaštite na radu u Nišu, Srbija, ORCID: 0000-0002-7931-9334,
snezana.zivkovic@znrfak.ni.ac.rs

Admir Šupić, Fakultet za tehničke studije, Univerzitet Travnik, BiH, ORCID broj: 0009-0001-6989-954X, email –
admirsupic@gmail.com

KRATAK SADRŽAJ

Psihosocijalni rizici, uključujući stres, sagorevanje, anksioznost, predstavljaju ozbiljne izazove za radnu efikasnost i zdravlje zaposlenih u savremenim industrijskim i uredskim uslovima. Tehnološki razvoj u oblasti nosivih uređaja (nosivi uređaji), IoT senzora, i umjetnička inteligencija omogućavaju kvantifikaciju i praćenje tih rizika u realnom vremenu, što može dovesti do preventivnih mjera. Globalna prevalencija: prema WHO-u, depresija i anksioznost dovode do gubitka ~12 milijardi radnih dana godišnje, uz ekonomske gubitke ~1 milijardu USD. U EU: 44,6% radnika prijavljuje rizike za mentalno zdravlje; ~27% je pokazalo stres, anksioznost ili depresiju vezano za posao. Relevantnost za BiH i regiju: SZO profil Bosne i Hercegovine ukazuje na značajne praznine u sistemskoj podršci mentalnog zdravlja na radnom mjestu.

Cilj rada: tehnički razraditi arhitekturu sistema za praćenje psihosocijalnih rizika, definirati metodologiju, implementirati analizu podataka, razmotriti regulativu i etiku.

Ključne reči: psihosocijalni rizici, IoT senzori, veštačka inteligencija, digitalni monitoring i mentalno zdravlje

ABSTRACT

Psychosocial risks, including stress, burnout, anxiety, pose serious challenges to the work efficiency and health of employees in modern industrial and office environments. Technological developments in the field of wearable devices (wearables), IoT sensors, and artificial intelligence enable the quantification and monitoring of these risks in real time, which can lead to preventive measures. Global prevalence: According to WHO, depression and anxiety lead to the loss of ~12 billion working days per year, with economic losses of ~1 billion USD. In the EU: 44.6% of workers report mental health risks; ~27% have shown work-related stress, anxiety or depression. Relevance for BiH and the region: The WHO profile of Bosnia and Herzegovina indicates significant gaps in systemic support for mental health in the workplace.

The goal of the work: to technically develop the architecture of the system for monitoring psychosocial risks, define the methodology, implement data analysis, consider regulations and ethics.

Key words: psychosocial risks, IoT sensors, artificial intelligence, digital monitoring, and workplace mental health.

UVOD

Savremeni radni procesi, obilježeni globalizacijom, digitalizacijom i stalnom potrebom za većom produktivnošću, značajno utiču na zdravlje i dobrobit zaposlenih. Prema podacima Evropske agencije za sigurnost i zdravlje na radu (EU-OSHA), više od 25% zaposlenih u Evropskoj uniji navodi stres kao glavni faktor koji negativno utiče na njihovo zdravlje [1]. Ovaj podatak ukazuje na to da je stres jedan od najčešćih problema

u savremenim radnim okruženjima, a psihosocijalni rizici poprimaju razmjere koje prevazilaze tradicionalni okvir zaštite na radu.

U prošlosti su sistemi bezbjednosti i zdravlja na radu bili prvenstveno usmjereni na fizičke rizike, poput mehaničkih povreda, hemijskih opasnosti, zaštite od požara ili buke [2]. Međutim, današnji radni uslovi sve više pokazuju da psihosocijalni faktori – stres, burnout sindrom, konflikti na radnom mjestu i nedostatak motivacije – imaju podjednako snažan, ako ne i jači, uticaj na sigurnost i zdravlje zaposlenih. Psihosocijalni rizici, iako često nevidljivi, generišu domino-efekat koji se manifestuje kroz smanjenje produktivnosti, povećanje broja bolovanja, fluktuaciju zaposlenih i ozbiljne posljedice po mentalno i fizičko zdravlje.

Istovremeno, razvoj digitalnih tehnologija, naročito Interneta stvari (IoT) i vještačke inteligencije (AI), otvara nove mogućnosti za unapređenje bezbjednosti i zdravlja na radu. IoT senzori, integrisani u pametne narukvice, radnu opremu ili u sam radni prostor, omogućavaju kontinuirano prikupljanje podataka o fiziološkim i bihevioralnim pokazateljima zaposlenih [3]. AI analitika, kroz složene algoritme mašinskog učenja i prediktivne modele, omogućava tumačenje tih podataka i pravovremeno prepoznavanje rizika prije nego što se oni manifestuju u obliku ozbiljnog zdravstvenog problema ili nesreće.

Ovaj rad ima za cilj da prikaže kako integracija IoT senzora i AI analitike može unaprijediti praćenje i prevenciju psihosocijalnih rizika na radnom mjestu. Poseban akcenat stavljen je na stres i burnout, jer predstavljaju najčešće i najštetnije oblike psihosocijalnih opterećenja. Rad će analizirati postojeće prakse, tehničke mogućnosti, izazove i etička pitanja, te dati preporuke za implementaciju ovih tehnologija u organizacijama u Bosni i Hercegovini i Evropskoj uniji.

PSIHOSOCIJALNI RIZICI

Psihosocijalni rizici predstavljaju sve one aspekte radnog okruženja, organizacije posla i međuljudskih odnosa koji mogu negativno uticati na psihičko zdravlje zaposlenih. Za razliku od fizičkih rizika, koji su često vidljivi i lako mjerljivi (npr. buka, hemikalije, visina), psihosocijalni rizici se nazivaju i „nevidljivim rizicima“. Njihove posljedice nisu odmah očigledne, ali njihov dugoročni uticaj na radnu populaciju može biti izrazito ozbiljan, uključujući smanjenje produktivnosti, povećanje bolovanja i ozbiljne zdravstvene probleme [4]. U modernim organizacijama, prepoznavanje i upravljanje ovim rizicima postaje ključni element strategije očuvanja zdravlja zaposlenih i povećanja efikasnosti poslovanja.

Stres

Stres na radnom mjestu javlja se kada zahtjevi posla premaše kapacitete zaposlenog da se s njima nosi. Uzroci stresa su raznovrsni i uključuju kratke i nerealne rokove, preopterećenost poslom, nedostatak jasnih uputa, nedovoljnu kontrolu nad zadacima, nejasne uloge u timu, te konflikte s nadređenima ili kolegama. Dugotrajna izloženost stresu može dovesti do ozbiljnih zdravstvenih problema, uključujući kardiovaskularne bolesti, depresiju, anksiozne poremećaje, probleme sa spavanjem i slabiju imunološku funkciju [5]. Istraživanja pokazuju da zaposleni pod hroničnim stresom imaju 30% veći rizik od povreda na radu, što implicira ne samo zdravstvene već i sigurnosne posljedice [6]. Pored fizičkih i mentalnih efekata, stres negativno utiče i na radnu motivaciju, zadovoljstvo poslom i ukupnu produktivnost organizacije. Zaposleni pod visokim nivoom stresa češće prave greške, imaju smanjenu kreativnost i veću stopu odsustva s posla. Organizacije koje zanemaruju psihosocijalne rizike rizikuju ne samo zdravlje svojih zaposlenih, već i ekonomsku stabilnost i reputaciju na tržištu.

Burnout

Burnout sindrom predstavlja specifičan oblik hroničnog stresa vezanog za posao i karakteriše se tri glavna elementa: emocionalnom iscrpljenošću, depersonalizacijom (ciničnim odnosom prema radu i saradnicima) i smanjenim osjećajem ličnog postignuća [7]. WHO je 2019. godine burnout uvrstila u Međunarodnu klasifikaciju bolesti (ICD-11) kao „profesionalni fenomen“, čime je naglašena njegova ozbiljnost i uticaj na globalnu radnu populaciju [8]. Posljedice burnouta su dugotrajne i sveobuhvatne. Osim pada produktivnosti i gubitka motivacije, može dovesti do fizičkih problema kao što su oslabljen imunitet, metabolički poremećaji,


gastrointestinalni problemi i povećan rizik od hroničnih bolesti. Takođe, burnout ima značajan socijalni uticaj jer može narušiti odnose unutar porodice i šire zajednice, što dodatno pogoršava kvalitet života zaposlenog.

Konflikti na radnom mjestu

Interpersonalni konflikti, mobing, loša komunikacija i nedostatak međusobnog povjerenja među članovima tima ubrajaju se među značajne psihosocijalne rizike. Ovi faktori povećavaju anksioznost, smanjuju osjećaj pripadnosti i motivaciju zaposlenih, a često rezultiraju i povećanom fluktuacijom radne snage [9]. Konflikti koji nisu pravovremeno rješavani mogu eskalirati u otvorene sukobe, što dodatno opterećuje organizaciju, povećava odsustvo s posla i smanjuje ukupnu produktivnost.

Ekonomija i statistika

Statistički podaci Evropske agencije za sigurnost i zdravlje na radu (EU-OSHA) pokazuju da stres i burnout zajedno čine više od 50% svih razloga za odsustvo s posla u Evropskoj uniji [10]. Prema procjenama Eurofound-a, psihosocijalni rizici evropsku ekonomiju godišnje koštaju približno 136 milijardi eura, uzrokovano gubitkom produktivnosti, povećanim brojem bolovanja i troškovima zdravstvene zaštite [11]. Ovi podaci jasno pokazuju da ignorisanje psihosocijalnih rizika nije samo problem zdravlja zaposlenih, već i ozbiljan ekonomski i društveni izazov. Upravljanje psihosocijalnim rizicima zahtijeva integrisan pristup, uključujući edukaciju zaposlenih i menadžera, jasnu organizaciju posla, podršku u kriznim situacijama, razvoj kulture otvorene komunikacije i preventivne mjere usmjerene na očuvanje mentalnog zdravlja. Organizacije koje uspješno implementiraju ovakve mjere ostvaruju dugoročne koristi, uključujući smanjenje odsustva, povećanje zadovoljstva i lojalnosti zaposlenih te poboljšanje ukupnih poslovnih rezultata.



DIJAGRAM 1 - Prosječan nivo stresa po sektorima

DIJAGRAM 2 - Predviđanje rizika od burnouta tokom godine

PRIMJENA DIGITALNIH TEHNOLOGIJA

Tradicionalna zaštita na radu fokusirala se na tehničke i organizacione mjere koje smanjuju rizik od povreda i nesreća. Međutim, digitalizacija uvodi potpuno novi pristup praćenju i zaštiti zaposlenih. IoT senzori i AI analitika ne samo da omogućavaju detaljniji i precizniji uvid u fizičke parametre radnog okruženja, već pružaju i mogućnost detekcije psihosocijalnih rizika kroz indirektno pokazatelje [12].

IoT senzori

IoT (Internet of Things) senzori su mali, povezani uređaji koji prikupljaju i prenose podatke u realnom vremenu. Njihova primjena u zaštiti na radu je široka:


- Praćenje temperature, vlage i kvaliteta vazduha na radnom mjestu;
- Wearable senzori za mjerenje pulsa, varijabilnosti srčanog ritma i nivoa kiseonika;
- Senzori u zaštitnoj opremi koji bilježe fizičke napore i pokrete radnika [13].

Kombinacijom podataka iz više izvora moguće je kreirati profil zaposlenog i pratiti promjene koje ukazuju na povećan nivo stresa ili premora. Na primjer, pad varijabilnosti srčanog ritma može signalizirati povećanu aktivaciju simpatičkog nervnog sistema, što je indikator stresa [14].

AI analitika

Vještačka inteligencija koristi algoritme mašinskog učenja za prepoznavanje obrazaca u podacima. U kontekstu zaštite na radu, AI može:

- Predvidjeti povećani rizik od nesreća na osnovu prethodnih incidenata;
- Analizirati digitalne komunikacione tokove (e-mail, chat) radi prepoznavanja znakova umora ili smanjene koncentracije;
- Kombinovati podatke o fizičkom i mentalnom zdravlju zaposlenih kako bi kreirala personalizovane preporuke [15].



DIJAGRAM 3 - Korelacija stresa i odsustva s posla

DIGITALNO PRAĆENJE PSIHOSOCIJALNIH RIZIKA

Praćenje psihosocijalnih rizika putem digitalnih tehnologija podrazumijeva korištenje biometrijskih podataka, prediktivne analitike i analize ponašanja zaposlenih.

Biometrijsko praćenje

Nosivi uređaji, poput pametnih satova i narukvica, bilježe fiziološke parametre zaposlenih: srčani ritam, nivo stresa, kvalitet sna. Analizom tih parametara moguće je identifikovati rane znakove stresa ili burnouta [16].



Prediktivna analitika

AI algoritmi obrađuju podatke dugoročnog karaktera, kao što su broj odrađenih prekovremenih sati, trendovi u produktivnosti i učestalost pauza. Na osnovu tih podataka AI može predvidjeti vjerovatnoću pojave burnout sindroma i generisati preporuke za prevenciju [17].

Analiza govora i ponašanja

Napredne AI platforme analiziraju ton glasa, ritam govora i obrasce komunikacije. Promjene u tim parametrima mogu ukazivati na povećan nivo stresa ili emocionalnu iscrpljenost [18]. Slično, analiza e-mail komunikacije može otkriti obrasce poput smanjene efikasnosti ili povećane frustracije.

Studija sprovedena u Njemačkoj pokazala je da kompanije koje koriste IoT i AI u nadzoru zaposlenih imaju 23% manje slučajeva bolovanja povezanih sa stresom [19].



DIJAGRAM 4 - Utjecaj digitalnog monitoringa na ključne pokazatelje (%), preciznost AI modela

IZAZOVI I ETIČKA PITANJA

Implementacija digitalnih tehnologija u praćenju psihosocijalnih rizika donosi i niz izazova i etičkih pitanja:

Privatnost podataka – Biometrijski i emocionalni podaci zaposlenih spadaju u posebno osjetljive informacije. Njihova zloupotreba može dovesti do diskriminacije, narušavanja prava na privatnost, pa čak i stigmatizacije određenih zaposlenih [20].

Povjerenje zaposlenih – Ukoliko zaposleni percipiraju tehnologiju kao sredstvo nadzora ili kontrole, to može dodatno povećati stres, smanjiti motivaciju i izazvati otpor prema korištenju sistema [21]. Transparentna komunikacija o svrsi i načinu korištenja tehnologija ključna je za održavanje povjerenja.

Tehnička ograničenja – IoT senzori i uređaji zahtijevaju stalno održavanje, kalibraciju i nadogradnju. AI modeli moraju biti precizni kako bi izbjegli lažno pozitivne ili negativne rezultate, a nepravilno trenirani algoritmi mogu dovesti do pogrešnih procjena rizika.

Regulativni okvir – U Evropskoj uniji prikupljanje i obrada podataka mora biti u skladu sa GDPR regulativom, što podrazumijeva stroge mjere zaštite podataka, anonimnost gdje je moguće i saglasnost zaposlenih [22].

Digitalni jaz i pristup tehnologiji – Nejednaka dostupnost i razumijevanje digitalnih alata može dovesti do nejednakosti među zaposlenima, posebno kod starijih radnika ili onih s manjim iskustvom u korištenju tehnologije.

Etička odgovornost – Postavlja se pitanje odgovornosti u slučaju da tehnologija pogrešno detektira stres ili burnout, što može utjecati na odluke menadžmenta, kao što su promjene radnog opterećenja ili disciplinske mjere.

Psihološki utjecaj stalnog nadzora – Senzori i algoritmi koji kontinuirano prate ponašanje zaposlenih mogu izazvati osjećaj konstantnog nadzora, što dugoročno povećava anksioznost, stres i osjećaj otuđenosti.


Balans između dobrobiti i kontrole – Implementacija tehnologije mora biti usmjerena na podršku zdravlju zaposlenih, a ne samo na kontrolu produktivnosti. Etika nalaže da mjere za praćenje rizika ne smiju biti zloupotrebljene za evaluaciju učinka zaposlenih.

Sigurnost podataka – Uz GDPR, potrebno je osigurati zaštitu od cyber napada. Podaci o emocionalnom i psihosocijalnom stanju zaposlenih su posebno osjetljivi i njihovo curenje može imati ozbiljne posljedice po reputaciju i povjerenje u organizaciju.

Socijalna stigmatizacija i diskriminacija – Algoritamske procjene mogu nenamjerno dovesti do etiketiranja zaposlenih kao "rizičnih" ili "problematičnih", što može izazvati socijalnu stigmatizaciju ili diskriminaciju unutar radne sredine.

Faktor rizika	Utjecaj na zdravlje	Posljedice za kompaniju
Stres	Depresija, nesanica, hipertenzija	Povećan broj bolovanja, nesreće
Burnout	Emocionalna iscrpljenost, imunitet	Pad produktivnosti, fluktuacija
Konflikti	Anksioznost, frstacija	Loša timska saradnja

SLIKA 1 - Grafički prikaz faktora rizika



SLIKA 2 - Prikaz tehničke infografije

ZAKLJUČAK

Integracija IoT senzora i AI analitike u sisteme zaštite na radu predstavlja značajan korak ka modernizaciji bezbjednosti i zdravlja na radnom mjestu. Korištenjem IoT uređaja, poput pametnih narukvica, nosivih senzora i okolinskih detektora, moguće je kontinuirano prikupljati podatke o fiziološkim parametrima zaposlenih (srčani ritam, variabilnost srca – HRV, nivo stresa, nivo aktivnosti) te o faktore okoline (temperatura, buka, nivo CO₂, osvetljenost). AI algoritmi omogućavaju obradu ovih velikih podataka u realnom vremenu, identifikovanje obrazaca ponašanja i predviđanje rizika od stresa ili burnouta. Primjena tehnika mašinskog učenja, poput neuronskih mreža i klasifikacionih algoritama, može dodatno unaprijediti preciznost procjene rizika i omogućiti personalizovane preporuke za intervenciju.

Ovakva digitalna transformacija donosi višestruke koristi: proaktivno prepoznavanje psihosocijalnih rizika, smanjenje troškova bolovanja i fluktuacije kadrova, poboljšanje produktivnosti i motivacije zaposlenih, te stvaranje sigurnijeg i zdravijeg radnog okruženja. Istovremeno, sistem omogućava menadžmentu donošenje informisanih odluka baziranih na objektivnim podacima, umjesto isključivo subjektivnih procjena.

Za kompanije u Bosni i Hercegovini i širem regionu preporučuje se:

- **Postepena implementacija IoT i AI tehnologija**, počevši od pilot projekata u odabranim odjelima ili proizvodnim linijama. Pilot projekti omogućavaju testiranje senzora, validaciju algoritama, optimizaciju prikupljanja podataka i minimiziranje tehničkih problema prije šire primjene.
- **Edukacija zaposlenih i menadžmenta** o funkcionalnostima sistema, svrsi prikupljanja podataka, etičkim principima i zaštiti privatnosti. Ovo uključuje trening za korištenje uređaja, interpretaciju dobijenih povratnih informacija i osvještavanje o prednostima preventivnog pristupa.
- **Usklađivanje sa EU regulativom o zaštiti podataka (GDPR)**, uključujući implementaciju enkripcije podataka, pseudonimizaciju ili anonimizaciju gdje je moguće, te osiguranje saglasnosti zaposlenih za prikupljanje i obradu podataka.
- **Razvoj interdisciplinarnih timova**, koji uključuju IT stručnjake, data scientiste, psihologe, stručnjake za zaštitu na radu, HR menadžere i menadžment. Takvi timovi mogu integrisati podatke iz različitih izvora, razviti algoritme za procjenu rizika i kreirati personalizovane preventivne mjere.
- **Tehnička infrastruktura**: preporučuje se implementacija edge computing sistema kako bi senzorski podaci bili analizirani lokalno i u realnom vremenu, smanjujući kašnjenje i opterećenje mreže. Cloud rješenja se mogu koristiti za dugoročno skladištenje, agregaciju i analitiku većih skupova podataka, uz visoku sigurnost i kontrolu pristupa.
- **Praćenje etičkih i socijalnih implikacija**, osiguravajući da tehnologija služi podršci zaposlenih, a ne kontroli ili stigmatizaciji. Ovo uključuje razvoj politika za transparentnu upotrebu podataka, redovne etičke revizije i uključivanje zaposlenih u kreiranje protokola.
- **Integracija povratnih informacija** zaposlenih i menadžmenta u sistem, čime se omogućava kontinuirano prilagođavanje algoritama, poboljšanje korisničkog iskustva i povećanje efikasnosti preventivnih mjera.

Buduća istraživanja trebala bi obuhvatiti različite industrijske sektore i testirati efikasnost ovih tehnologija u stvarnim radnim okruženjima, uključujući proizvodne, administrativne i uslužne sektore. Poseban fokus treba staviti na razvoj standardizovanih metodologija za mjerenje psihosocijalnih rizika putem digitalnih alata, validaciju AI modela kroz longitudinalne studije, te evaluaciju dugoročnog uticaja na zdravlje, zadovoljstvo i produktivnost zaposlenih.

U konačnici, implementacija IoT i AI tehnologija u sistemima zaštite na radu predstavlja ne samo tehnološki napredak, već i strateški korak ka stvaranju organizacija koje brinu o dobrobiti svojih zaposlenih, unapređujući sigurnost, zdravlje i ukupnu otpornost radne snage

LITERATURA

- [1] World Health Organization. Mental Health at Work: Fact Sheet. 2024. Dostupno na: who.int
- [2] Eurostat. Self-reported work-related health problems and risk factors — key statistics. 2020.
- [3] EU-OSHA. OSH Pulse – Psychosocial risks and mental health. 2022.
- [4] ISO. ISO 45003:2021 — Psychological health and safety at work.

- [5] GDPR — Article 88: Processing in context of employment.
- [6] McCraty, R., et al. "Heart Rate Variability as a Marker of Stress Regulation and Health: A Review". *Frontiers in Neuroscience*, 2021.
- [7] Setz, C., et al. "Discriminating Stress From Cognitive Load Using a Wearable EDA Device". *IEEE Transactions on Affective Computing*, 2010.
- [8] Basner, M., et al. "Auditory and non-auditory effects of noise on health". *The Lancet*, 2014.
- [9] Hedge, A. "Noise, vibration, and worker performance: Methods for studying individual response". *Journal of Engineering Ergonomics*, 2000.
- [10] Picard, R. W., et al. "Wearable Sensors for Stress Monitoring: Methods and Challenges". *Annals of Biomedical Engineering*, 2016.
- [11] Kim, H.-G., et al. "Standardization of HRV measurements: frequency domain, time domain, non-linear measures: implications for workplace stress monitoring." *Sensors*, 2023.
- [12] Vos, G., et al. "Generalizable Machine Learning for Stress Monitoring from Wearable Sensors". *Computers in Human Behavior*, 2023.
- [13] Pinge, A., et al. "Advances in real-time stress detection: Combined biosignal-environmental sensor systems." *Frontiers in Computer Science*, 2024.
- [14] National Institute for Occupational Safety and Health. *Stress at Work*. CDC/NIOSH Publication No. 99-101.
- [15] American Psychological Association. *Work and Well-Being Survey Report*. 2023.
- [16] International Labour Organization. *Psychosocial Risks and Stress at Work*. Geneva, 2016.
- [17] Hancock, P. A., & Desmond, P. A. *Stress, Workload, and Fatigue*. CRC Press, 2001.
- [18] Healey, J., & Picard, R. W. "Detecting Stress During Real-World Driving Tasks Using Physiological Sensors." *IEEE Transactions on Intelligent Transportation Systems*, 2005.
- [19] Taelman, J., et al. "Influence of Mental Stress on Heart Rate and Heart Rate Variability." *IFMBE Proceedings*, 2009.
- [20] Gjoreski, M., et al. "Continuous Stress Detection Using a Wrist Device: In Laboratory and Real Life." *UbiComp Proceedings*, 2016.
- [21] National Fire Protection Association. *NFPA 1500 — Standard on Fire Department Occupational Safety, Health, and Wellness Program*. Latest edition.
- [22] World Health Organization. *Occupational Noise: Assessing the Burden of Disease from Work-Related Hearing Impairment*. 2018..