

PREDIKCIA VYSOKEJ PRODUKTIVITY ŠTUDENTOV V KONTEXTE DIGITÁLNEHO ROZPTÝLENIA A PRÍSTUPU K ŠTÚDIU

Úvod

Akademická výkonnosť a produktivita je v súčasnosti výzvou predovšetkým kvôli digitálnym technológiám, ktoré vedia byť výborným pomocníkom, ale zároveň často prispievajú k rozptyľovaniu a prokrastinácii. Výskumy ukazujú, že používanie sociálnych médií pozitívne koreluje s akademickým výkonom ak je integrované do vyučovacieho procesu (napr. Alshalawi, 2022), môže ísť teda o pozitívny aspekt prispievajúci k vzdelávaniu, avšak na druhej strane sú známe aj mnohé negatívne dopady na akademické výsledky. Štúdia Kolhara a kol. (2021) napríklad popisuje, že 97% z 300 skúmaných študentov využíva sociálne siete, avšak iba 1% ich využíva pre akademické účely. Nadmerné využívanie sociálnych sietí vyčerpáva kognitívne zdroje, čo vedie k zníženiu času a energie na akademické aktivity. Okrem rozptýlenia od akademickej práce sociálne siete významne narušujú spánok, čo ďalej narúša efektivitu počas dňa a môže byť spojené až so školským vyhorením (Evers a kol., 2020). Negatívne dopady nadmerného používania mobilných zariadení dnes označuje aj pojem *technostres*, ktorý môžeme definovať ako stres vznikajúci v dôsledku používania informačných technológií a ukazuje sa, že tiež súvisí s akademickým výkonom (Yao & Wang, 2023). Vysoká úroveň stresu celkovo je ďalším z faktorov ovplyvňujúcich vzdelávanie - okrem akademického výkonu môže negatívne pôsobiť aj na fyzické a mentálne zdravie, celkovú životnú spokojnosť či vnímanú vlastnú účinnosť (self-efficacy) (Hitches a kol., 2022).

Keďže produktivita študentov je kľúčová pre ich akademickú úspešnosť, rozhodli sme sa preskúmať vplyv aspektov akými je využívanie sociálnych sietí, úroveň stresu, spánok a množstvo času venované štúdiu, aby sme zistili, ktoré faktory prispievajú k vysokej produktivite a ktoré naopak produktivitu znižujú.

Máme k dispozícii súbor obsahujúci 19 222 študentov¹. U týchto študentov bolo namerané skóre produktivity v rozsahu 0-100 bodov. Nakoľko priemerné skóre súboru bolo 50,18 bodov, pre účely binomiálnej logistickej regresie sme sa rozhodli stanoviť hranicu 70 a viac bodov ako skóre označujúce vysokú produktivitu. V analýze teda pracujeme s premennou vysoká produktivita, ktorá zahŕňa jednotlivcov so skóre produktivity vyšším ako 70 (1) a nižším ako 70 (0). Z dátového súboru budú pomocou numerických metód získané parametre tohto modelu.

Popis premenných dátového súboru

Závislá premenná

- **High productivity:** Vysoká produktivita stanovená podľa dosiahnutého skóre produktivity
 - 0 = skóre produktivity nižšie ako 70 bodov
 - 1 = skóre produktivity vyššie ako 70 bodov


¹ Dáta a ďalšie informácie o tejto správe sú dostupné na adrese <https://dostal.vyzkum-psychologie.cz/stat4?i=624>

Nezávislé premenné

- **Age:** Vek študentov
- **Gender:** Pohlavie² študentov (0 = žena, 1 = muž)
- **Stress level:** Subjektívne vnímaná úroveň stresu (škála 1-10)
- **Sleep hours:** Počet hodín spánku
- **Study hours per day:** Počet hodín venovaných učeniu
- **Social media hours:** Počet hodín strávených na sociálnych sieťach
- **Phone usage hours:** Počet hodín strávených používaním telefónu

Výsledky logistickej regresie

Binárna logistická regresia bola vypočítaná v programe Jamovi (verzia 2.6.45). Výsledky sú uvedené v tabuľke 1. V logistickej regresii sa odhadnuté parametre modelu (tzv. β koeficienty) neinterpretujú priamo, pretože sa vyskytujú ako exponenty v logistickej funkcii. Lepším parametrom je namiesto toho pomer šancí (Odds Ratio, OR), ktorý sa vypočíta ako e^{β} , kde e je Eulerovo číslo. Pomer šancí nám ukazuje, ako zmena danej nezávislej premennej ovplyvňuje šancu na výskyt skúmaného javu – v našom prípade vysokej produktivity študenta. Napríklad pre premennú Study hours per day (denný čas štúdia) hovorí, že ak zvýšime čas štúdia o jednu hodinu, šanca na dosiahnutie vysokej produktivity sa zvýši 3,046-krát. Naopak, pri premennej Phone usage hours (hodiny používania telefónu) nám pomer šancí 0,679 hovorí, že ak zvýšime čas na telefóne o jednu hodinu, šanca na vysokú produktivitu klesne o 32,1 % ($1 - 0,679 = 0,321$). Efekt hodín štúdia a hodín používania telefónu na vysokú produktivitu je graficky znázornený na obrázku 1.



Obrázok 1

Teraz sa pozrieme na to, ktoré premenné sú štatisticky významné, teda u ktorých môžeme zamietnuť nulovú hypotézu parametru $\beta_i = 0$. **Ukázalo sa, že štatisticky významný vplyv na vysokú produktivitu študentov má: úroveň stresu, počet hodín spánku, počet hodín štúdia**

² Z pôvodného súboru boli pre účely analýzy vplyvu pohlavia vyradení respondenti v kategórii „Other“ z dôvodu ich nízkeho zastúpenia. Finálna analýza tak pracovala s binárnou premennou (muž/žena).

a množstvo času stráveného na telefóne. Naopak vek, pohlavie a počet hodín strávených na sociálnych sieťach štatisticky významnými prediktormi v tomto modeli nie sú.

Tabuľka 1: Odhad parametrov modelu

Prediktor	Odhad parametru	Št. odchýlka	Z	p	Pomer šancí
Intercept	-11,43907	0,32908	-34,761	<,001	1,08e-5
Age	0,00936	0,00842	1.112	0,266	1,009
Stress level	-0,25796	0,01192	-21,648	<,001	0,773
Sleep hours	0,66987	0,01937	34,581	<,001	1,954
Study hours per day	1,10997	0,02501	44,386	<,001	3,034
Social media hours	-0,01162	0,01371	-0,847	0,397	0,988
Phone usage hours	-0,38612	0,01164	-33,169	<,001	0,680
Gender:	-0,11721	0,06333	-1,851	0,064	0,889

Tabuľka 2: Ukazovatele kvality modelu

Odchýlka	AIC	R ² _{McF}	R ² _{CS}	R ² _N	χ ²	df	p
6546	6562	0,528	0,316	0,616	7308	7	<,001

Štatistickú kvalitu zostaveného modelu sumarizuje tabuľka 2. P-hodnota je veľmi nízka (<,001), čo potvrdzuje, že náš model dokáže efektívne predikovať vysokú úroveň produktivity u študentov. Ukazovatele R² predstavujú analógiu koeficientov determinácie, ktoré používame v lineárnych modeloch. McFaddenovo R² dosahuje v našom prípade hodnotu 0,528, čo naznačuje vynikajúcu zhodu modelu s nameranými dátami. Koeficient R² podľa Coxa a Snella je 0,443. Keďže tento ukazovateľ nemôže nadobudnúť hodnotu 1, korigujeme ho pomocou Nagelkerkeho R², ktoré v našom modeli dosahuje hodnotu 0,818, na základe čoho môžeme konštatovať, že model vysvetľuje približne 81,8 % rozptylu závislej premennej (vysokej produktivity).

Tabuľka 3: Ukazovatele kvality predikcie modelu

Presnosť	Špecifická	Senzitivita
0,921	0,971	0,550

Prediktívne schopnosti modelu nájdeme v tabuľke 3. Celková presnosť modelu dosahuje 92,2 %, čo znamená, že model správne klasifikuje väčšinu prípadov v rámci nášho súboru dát.

Špecifická, teda schopnosť modelu správne identifikovať študentov, ktorí nedosiahnu vysokú produktivitu, je tiež vysoká (97,1 %). Naopak senzitivita, ktorá hovorí o schopnosti modelu správne identifikovať študentov, ktorí skutočne sú vysoko produktívni, dosahuje o niečo nižšiu hodnotu (55,1 %). Znamená to, že náš model vynikajúco rozpoznáva študentov s priemernou alebo nižšou produktivitou, no pri identifikácii tých „najlepších“ (najviac produktívnych) je o niečo menej presný. Hraničná hodnota pre klasifikáciu bola nastavená na štandardnej úrovni 0,5.

Tabuľka 4: Klasifikačná tabuľka

Pozorované	Predikcia		% Správnych
	0	1	
0	16479	499	97,1
1	1010	1234	55,0

Schopnosť modelu správne zaradiť študentov do kategórie s vysokou produktivitou môžeme posúdiť aj prostredníctvom klasifikačnej tabuľky. Vidíme, že model správne identifikoval 16479 študentov, ktorí vysokú produktivitu nedosiahli a iba v 499 prípadoch vysokú produktivitu predpovedal nesprávne. Naopak, z 2244 skutočne vysoko produktívnych študentov model správne identifikoval 1234, zatiaľ čo 1010 bolo nesprávne klasifikovaných ako neproduktívnych. To zodpovedá vysokej špecifícite modelu (97,1 %) a nižšej senzitivite (55,0 %), model je spoľahlivejší pri identifikácii študentov, ktorí nedosiahnu vysokú produktivitu, než pri predikcii tých, ktorí ju skutočne dosiahnu.

Záverečné zhodnotenie

Pomocou binomiálnej logistickej regresie sa podarilo vytvoriť štatisticky významný model predikcie vysokej produktivity študentov, v rámci ktorého sme ako štatisticky významné pozitívne faktory identifikovali čas venovaný štúdiu a dĺžku spánku. Negatívny vplyv na vysokú produktivitu sme potvrdili u času strávenom na telefóne a úrovne stresu. Premenné vek, pohlavie a čas strávený na sociálnych sieťach sa v tomto modeli neukázali ako signifikantné. Model má vysokú celkovú presnosť (92,1 %) a veľmi dobre identifikuje študentov, ktorí vysokú produktivitu nedosiahnu (špecifická 97,1 %). Predikcia vysokej produktivity je však menej presná, pretože senzitivita modelu dosahuje 55,0 %. To znamená, že model správne predpovedá vysoký výkon približne u polovice študentov, ktorí sú v skutočnosti vysoko produktívni.

Použitá literatúra

Alshalawi, A. S. (2022). Social media usage intensity and academic performance among undergraduate students in Saudi Arabia. *Contemporary Educational Technology* 14(2), 361. <https://eric.ed.gov/?id=EJ1341240>

Evers, K., Sufen, Ch., Rothmann, S., Amandeep, D., & Pallesen, S. (2020). Investigating the relation among disturbed sleep due to social media use, school burnout, and academic performance. *Journal of Adolescence*, 84, 156-164. <https://doi.org/10.1016/j.adolescence.2020.08.011>

Hitches, E., Woodcock, S., & Ehrich, J. (2022). Building self-efficacy without letting stress knock it down: Stress and academic self-efficacy of university students. *International Journal of Educational Research Open*, 3, 100124. <https://doi.org/10.1016/j.ijedro.2022.100124>

Kolhar, M., Kazi, R. N. A., & Alameen, A. (2021). Effect of social media use on learning, social interactions, and sleep duration among university students. *Saudi Journal of Biological Sciences*, 28(4), 2216-2222. <https://doi.org/10.1016/j.sjbs.2021.01.010>

Yao, N., & Wang, Q. (2023). Technostress from smartphone use and its impact on university students' sleep quality and academic performance. *The Asia-Pacific Education Researcher*, 32, 317-326. <https://doi.org/10.1007/s40299-022-00654-5>