VIJESTI IZ ZNANOSTI

Razvoj novih materijala u 2026. godini pokriva vrlo široko područje od pametnog dizajna do autonomnog otkrivanja materijala

Godina 2026. donosi novu fazu u razvoju znanosti o materijalima. Nakon desetljeća u kojima su istraživači nove materijale uglavnom otkrivali kombiniranjem eksperimentalnog rada, teorijskih modela i postupnog optimiranja sastava i strukture, danas se sve snažnije razvija pristup u kojem umjetna inteligencija, velike baze podataka, računalne simulacije i automatizirani laboratoriji zajednički sudjeluju u procesu otkrivanja i razvoja materijala.

Suvremena znanost o materijalima tako se sve više udaljava od klasičnog modela „pokušaja i pogreške". Umjesto da istraživač ispituje velik broj mogućih kombinacija elemenata, struktura i procesnih uvjeta, umjetna inteligencija može analizirati goleme količine postojećih podataka, prepoznati obrasce koji čovjeku nisu lako uočljivi te predložiti nove materijale s unaprijed određenim svojstvima. Takav pristup posebno je važan kod vrlo složenih sustava, primjerice legura s velikim brojem elemenata, polimera, katalizatora, elektrolita i kvantnih materijala.
Istodobno, 2026. godina pokazuje da cilj više nije samo predvidjeti kakav bi materijal mogao biti uspješan. Sve je važnije povezati predviđanje s eksperimentom. Razvijaju se sustavi u kojima AI odabire sljedeći eksperiment, robotski sustav ga provodi, rezultati se automatski analiziraju, a dobiveni podaci ponovno ulaze u model. Na taj način nastaje zatvoreni krug učenja u kojem se svaki novi eksperiment koristi za poboljšanje sljedeće odluke. Upravo se takav koncept povezuje s razvojem autonomnih ili „self-driving" laboratorija.
AI postaje novi partner znanstvenika

Jedan od najvažnijih trendova 2026. godine jest ubrzana integracija umjetne inteligencije u gotovo sve faze razvoja materijala. AI se danas koristi za predviđanje svojstava, generiranje novih struktura, optimiranje sastava, analizu eksperimentalnih podataka, pretraživanje znanstvene literature i planiranje eksperimenata. Posebno se razvijaju generativni modeli, neuronske mreže, aktivno učenje i Bayesova optimizacija.

Velike baze podataka pritom postaju jednako važne kao i sami algoritmi. Primjerice, Materials Project početkom 2026. godine obuhvaćao je više od 200 000 računalno proučenih materijala i stotine tisuća molekula, a njegova se infrastruktura koristi u istraživanjima baterija, kvantnog računarstva, mikroelektronike i katalize.

Posebno je zanimljiv prijelaz prema multimodalnoj umjetnoj inteligenciji. Za potpuno razumijevanje materijala nije dovoljno znati samo njegov kemijski sastav. Potrebno je istodobno povezati informacije o kristalnoj i mikrostrukturnoj građi, načinu priprave, procesnim uvjetima, mehaničkim, električnim i optičkim svojstvima te rezultatima karakterizacije. Upravo integracija takvih različitih vrsta podataka postaje jedan od ključnih izazova suvremene znanosti o materijalima.
No, unatoč velikom napretku, umjetna inteligencija nije zamjena za znanstvenika. Materijal koji računalni model predvidi kao zanimljiv kandidat mora se još uvijek sintetizirati, karakterizirati i eksperimentalno potvrditi. Posebno je važno osigurati da AI modeli poštuju temeljne zakone fizike i kemije te da njihova predviđanja budu provjerljiva. Upravo se zato u 2026. sve više govori o „physics-grounded AI", odnosno umjetnoj inteligenciji koja u proces predviđanja uključuje fizikalna i kemijska ograničenja.

Novi materijali zadobivanje, transport i pohranu energije
Jedno od najvažnijih područja primjene novih materijala ostaje energetika. Razvoj baterija, gorivnih članaka, katalizatora i materijala za proizvodnju i pohranu energije zahtijeva materijale koji istodobno moraju biti učinkoviti, stabilni, sigurni i dostupni u dovoljnim količinama. Posebno zanimljivo područje predstavlja razvoj čvrstih elektrolita za solid-state baterije. U 2026. godini AI se sve intenzivnije povezuje s računalnim metodama kao što su teorija funkcionala gustoće, molekularna dinamika i strojno učenje atomskih potencijala. Cilj je brže razumjeti kretanje iona, stabilnost sučelja između elektrolita i elektroda te pronaći nove sastave koji bi mogli zadovoljiti istodobno više zahtjeva.
Ovaj primjer dobro pokazuje promjenu paradigme: budući materijal ne traži se samo prema jednom svojstvu, primjerice visokoj ionskoj vodljivosti, nego prema cijelom skupu svojstava – vodljivosti, mehaničkoj stabilnosti, kemijskoj kompatibilnosti, sigurnosti, cijeni, dostupnosti sirovina i mogućnosti proizvodnje u većem mjerilu.

Umjetna inteligencija i održivi materijali
Održivost postaje jedan od temeljnih kriterija pri projektiranju novih materijala. Materijal budućnosti mora biti ne samo funkcionalan nego i resursno učinkovit, sigurniji za okoliš te prikladan za recikliranje ili ponovnu uporabu.
Upravo se ovdje AI pokazuje posebno korisnim. Analizom velikih skupova podataka moguće je istodobno optimirati više ciljeva: mehanička svojstva, trajnost, cijenu, energetsku potrošnju, udio kritičnih elemenata i utjecaj na okoliš. U 2026. pojavljuju se i AI sustavi usmjereni na razvoj održivijih metalnih legura. Primjerice, istraživači u Indiji razvili su platformu povezanu s bazom od oko 185 000 zapisa o legurama, s ciljem ubrzavanja pronalaženja metalnih materijala visokih svojstava i boljeg profila održivosti.
Sličan se pristup sve više primjenjuje i na polimere. Njihov razvoj posebno je složen jer konačna svojstva ne ovise samo o kemijskom sastavu, nego i o duljini i organizaciji polimernih lanaca, načinu obrade, temperaturi, vremenu i hijerarhijskoj strukturi. Najnoviji pristupi pokušavaju zato povezati AI, baze podataka, simulacije i automatizirano eksperimentiranje u jedinstven sustav.

Kvantni i funkcionalni materijali
Drugo veliko područje razvoja predstavljaju kvantni materijali. Njihova svojstva proizlaze iz kvantnomehaničkih pojava koje mogu omogućiti potpuno nove načine prijenosa elektrona, obrade informacija, senzorske funkcionalnosti i pohrane energije.

U 2026. godini posebno se intenzivno istražuju materijali povezani sa supravodljivošću, neobičnim magnetskim svojstvima i drugim kvantnim fenomenima. Istodobno se AI i kvantno računarstvo počinju koristiti zajedno u nastojanju da se složena svojstva takvih materijala bolje razumiju i da se ubrza potraga za novim kandidatima.
Takav razvoj predstavlja zanimljiv znanstveni paradoks: kvantno računarstvo i kvantni materijali mogu postati istodobno predmet istraživanja i alat za istraživanje drugih materijala. Time se otvara mogućnost razvoja potpuno novih istraživačkih metoda koje povezuju fiziku, kemiju, računarstvo i inženjerstvo.

Znanost o materijalima i podatkovna znanost
Jedna od najvažnijih poruka 2026. godine jest da budućnost materijala neće ovisiti samo o tome koliko dobro možemo sintetizirati novi materijal, nego i o tome koliko dobro možemo prikupljati, organizirati, povezivati i interpretirati podatke o njemu.
Podaci o sastavu, strukturi, procesnim uvjetima, svojstvima i ponašanju materijala sve se više povezuju u digitalne sustave. Time se razvija nova paradigma u kojoj materijalna znanost postaje istodobno i podatkovna znanost. FAIR načela – pronalažljivost, dostupnost, interoperabilnost i ponovna uporabljivost podataka – postaju važna infrastruktura za razvoj novih materijala.
To je osobito važno za interdisciplinarna područja. Podaci dobiveni spektroskopijom, mikroskopijom, difrakcijom, termičkom analizom ili mehaničkim ispitivanjem više se ne promatraju odvojeno. Njihovo povezivanje može omogućiti stvaranje puno potpunije slike o materijalu i njegovu ponašanju.

Što nam donosi budućnost?
Ako se razvoj započet posljednjih godina nastavi, znanost o materijalima mogla bi ući u razdoblje u kojem će se novi materijali sve češće projektirati prije nego što budu sintetizirani. Umjesto pitanja „Koja svojstva ima ovaj materijal?”, sve će važnije postajati pitanje „Koji materijal trebamo projektirati da bismo dobili željena svojstva?”
U tom smislu 2026. godina predstavlja važnu prijelomnu točku. Umjetna inteligencija, računalne simulacije, velike baze podataka, robotika i napredne metode karakterizacije počinju djelovati kao dijelovi jedinstvenog istraživačkog ekosustava. Istodobno, tradicionalno znanje iz kemije, fizike, biologije i inženjerstva ostaje nezamjenjivo jer upravo ono omogućuje razumijevanje rezultata i postavljanje smislenih znanstvenih pitanja.
Budućnost stoga vjerojatno neće pripadati ni umjetnoj inteligenciji ni čovjeku pojedinačno, nego njihovoj suradnji. Najuspješniji će biti oni istraživački sustavi u kojima AI može brzo pretraživati goleme prostore mogućih rješenja, dok znanstvenik definira ciljeve, procjenjuje vjerodostojnost rezultata, razumije fizikalnu i kemijsku pozadinu te donosi konačne odluke.
Upravo se u tome nalazi najveći potencijal nove generacije znanosti o materijalima: materijali se više ne razvijaju samo otkrivanjem onoga što priroda nudi, nego sve više ciljanim projektiranjem onoga što je društvu i tehnologiji potrebno.