Food Technol. Biotechnol. 63 (2) 124-133. www.ftb.com.hr
FTB-8792

Integracija umjetne neuronske mreže (ANN) i simulacije procesa za prediktivno modeliranje uklanjanja H_2S pomoću biološkog sustava za ispiranje bioplina dobivenog iz otpadnih voda nastalih tijekom industrijske proizvodnje palminog ulja

SAŽETAK

Pozadina istraživanja. Proizvodnja bioplina iz otpadnih voda dobivenih tijekom proizvodnje palminog ulja (engl. palm oil mill effluent - POME) je nestabilna zbog oscilacija u sastavu sirovine i uvjetima njene prerade. Ta odstupanja mogu dovesti do neujednačene kvalitete bioplina, promjenjivog udjela metana i nestabilne koncentracije sumporovodika (H_2S). To stvara značajne probleme u primjeni biološkog sustava za ispiranje (uklanjanje) H_2S (engl. bioscrubber) s ciljem zadovoljavanja standarda kvalitete za proizvodnju električne energije pomoću plinskih kogeneracijskih sustava. Svrha je ovog istraživanja bila prevladati ove probleme integracijom simulacijskih modela s računalnim programom i umjetnom neuronskom mrežom (eng. artificial neuron network; ANN) za predviđanje učinkovitosti biološkog sustava za ispiranje H_2S u postrojenju za obradu otpadnih voda dobivenih tijekom proizvodnje palminog ulja u Johoru, Malezija.

Eksperimentalni pristup. Na početku istraživanja je simuliran tijek proizvodnog procesa pomoću računalnog programa. Potom je uklanjanje H_2S predviđeno korištenjem algoritma strojnog učenja, konkretno ANN-a, temeljenog na dvogodišnjim proizvodnim podacima dobivenim u bioplinskom postrojenju. Također je provedena detaljna tehnološko-ekonomska analiza, radi utvrđivanja ekonomske izvedivosti bioprocesa.

Rezultati i zaključci. Rezultati simulacije pokazali su da bi prinos bioplina trebao biti 26,12 Nm^3 po m^3 otpadnih voda dobivenih tijekom proizvodnje palminog ulja, što je u skladu s industrijskim podacima, s manje od 1 % odstupanja. ANN model imao je veliki koeficijent determinacije (R^2) od 0,9 i malu srednju kvadratnu pogrešku (MSE), pri čemu je biološki sustav za ispiranje H_2S imao učinkovitost od približno 96 %. Tehnološko-ekonomska analiza pokazala je da je bioproces izvediv s neto sadašnjom vrijednošću od 131.000 USD i razdobljem povrata od 7 godina.

Novina i znanstveni doprinos. Integracija ANN-a i računalnog programa pruža robustan okvir za predviđanje učinkovitosti rada bioloških sustava za ispiranje H_2S (engl. bioscrubber) i osigurava njihov stabilan rad uslijed komplementarnog djelovanja ANN i računalnog programa. ANN precizno predviđa uklanjanje H_2S na temelju dnevno zabilježenih podataka, dok računalni program procjenjuje parametre

koji se ne prate na dnevnoj osnovi, poput kemijske potrebe za kisikom (COD), biološke potrebe za kisikom (BOD) i ukupne topljive suhe tvari (TSS). Ovo istraživanje pruža važan uvid u održive prakse proizvodnje bioplina i nudi mogućnost poboljšanja energetske učinkovitosti i ekološke održivosti industrije proizvodnje palminog ulja.

Ključne riječi: otpadne vode dobivene tijekom proizvodnje palminog ulja; bioplin; simulacija; umjetna neuronska mreža; biološki sustav za ispiranje H_2S