

NEURAL MODELLING OF THERMAL PROCESSES DURING COMPOSTING OF CHOSEN NATURAL FERTILIZERS

Summary

Composting process depends on microbiological decomposition of organic matter in oxygenic conditions proceeded by the thermophile microorganisms and moulds. During the process there is a lot of heat energy emission which can be used for different aims. There is no information about neural network used for modelling of composting processes in the world publications. The objective of presented work was to model the composting process of solid natural fertilizers using the artificial neural networks. I focused mainly on thermal analysis of this process. Qualification of heat emission as a result of exothermic reactions during composting process was the focus of attention. The second stage was complex analysis as well as creating, testing and verification of series of neural networks topology. The analytical software package Statistica v. 7.1: 'Neural Networks' was used. Low ratio of standard deviations and correlation coefficient close to one, provide the most important information for the good assessment of the neural network.

MODELOWANIE NEURONOWE PROCESÓW CIEPLNYCH ZACHODZĄCYCH PODCZAS KOMPOSTOWANIA WYBRANYCH NAWOZÓW NATURALNYCH

Streszczenie

Proces kompostowania polega na mikrobiologicznym rozkładzie substancji organicznych w warunkach tlenowych za pomocą mikroorganizmów termofilnych i pleśni. Podczas procesu kompostowania wydzielają się duże ilości ciepła, które może być wykorzystane do różnych celów. W literaturze światowej brak jest informacji o wykorzystaniu sieci neuronowych w modelowaniu procesów cieplnych zachodzących podczas kompostowania. Celem prezentowanej pracy było modelowanie procesu kompostowania stałych nawozów naturalnych z wykorzystaniem sztucznych sieci neuronowych, ze szczególnym uwzględnieniem analizy cieplnej zachodzących zjawisk. Skupiono się na estymacji ilości ciepła otrzymywanego w wyniku reakcji egzotermicznych zachodzących podczas procesu kompostowania. Dokonano analizy oraz wytworzono, przetestowano i zweryfikowano zbiór topologii sieci neuronowych, działających jako efektywne instrumenty predykcyjne. W tym celu wykorzystano pakiet oprogramowania analitycznego Statistica v. 7.1 moduł: „Sieci Neuronowe”. Mała wartość ilorazu odchyleń standardowych oraz współczynnik korelacji bliski jedności świadczy o dobrej jakości otrzymanych sieci neuronowych.

1. Wstęp

Jednym z ważniejszych problemów współczesnego świata są efekty uboczne związane z szeroko rozumianym rynkiem energetycznym i wynikające z nich zagrożenia środowiska naturalnego. Wykorzystanie konwencjonalnych źródeł energii, takich jak węgiel, ropa oraz pochodne, wiąże się m.in. ze wzrostem emisji do atmosfery różnego rodzaju zanieczyszczeń. Skutkuje to negatywnym wpływem na całokształt środowiska. Źródła te nie są również niewyczerpalne, co wiąże się ze stałym wzrostem cen energii na rynku światowym. W związku z powyższym przyszłość mogą stanowić m.in. metody związane z tzw. zrównoważonymi systemami energetycznymi, a w szczególności z odnawialnymi źródłami energii. Źródła energii takie jak biogaz, biopaliwa, wiatr, słońce czy woda, zgodnie z zarządzeniami Unii Europejskiej mają do 2020 roku stanowić min. 20% udziału w całości wyprodukowanej energii.

Nawozy naturalne są ważnym, wręcz niezastąpionym źródłem substancji odżywczych w glebie. Posiadają one istotny wpływ m.in. na jakość gleb i (wynikający z tego) wzrost plonowania roślin. W Polsce najczęściej stosowanymi nawozami naturalnymi są obornik oraz gnojowica. Ich wykorzystanie wiąże się jednak z koniecznością spełnienia wielu, często kosztownych, wymogów [8]. Chodzi tu głównie o odpowiednie przechowywanie oraz rozpraszanie nawozu na powierzchni pola. Największymi zagrożeniami dla środowiska

naturalnego są w tym wypadku: emisja amoniaku oraz proces wymywania substancji mineralnych z gleby. Elementy te wpływają również na straty składników nawozowych.

Kompostowanie jest jednym ze sposobów, który może być wykorzystany przy rozwiązywaniu wspomnianych powyżej problemów. Proces kompostowania polega na rozkładzie substancji organicznych, zachodzący w warunkach tlenowych, pod wpływem tzw. mikroorganizmów termofilnych oraz pleśni. Charakteryzuje się długą fazą egzotermiczną, podczas której temperatura kompostowanej substancji wzrasta do 65-75°C. Wydzielają się więc duże ilości „zielonej” energii cieplnej, która może być wykorzystana do różnych celów, takich jak np.: ogrzewanie budynków inwentarskich czy szklarni. Efektem omawianego procesu jest stabilny, wartościowy oraz bezpieczny pod względem sanitarnym, nawóz [2]. Jego właściwości odżywcze są jakościowo lepsze od standardowo przechowywanego obornika. Kompostowanie jest jednak procesem złożonym, o bardzo skomplikowanych zależnościach biologiczno-chemicznych. W związku z tym proces ten jest trudny do formalnego opisu z wykorzystaniem klasycznych metod modelowania.

Efektywnym instrumentem przydatnym do rozwiązywania złożonych problemów naukowych są, coraz częściej wykorzystywane w praktyce inżynierskiej, sztuczne sieci neuronowe. Ze względu na ich specyficzny charakter w praktyce wykorzystuje się je na ogół w formie rozbudowanych systemów infor-

matycznych, będących w swojej istocie numerycznymi symulatorami komputerowymi. Czerpiąc inspirację z budowy oraz funkcjonowania ludzkiego mózgu, symulują one jego najważniejsze funkcje, takie jak zdolność do uczenia się oraz umiejętność generalizowania zdobytej wiedzy. Są to niewątpliwe atuty przy tworzeniu semantycznych modeli badanych procesów biologicznych [5]. To nowatorskie podejście stosowane jest również na coraz szerszą skalę w różnych aplikacjach inżynierii rolniczej [1, 3, 7]. W literaturze dotyczącej omawianego tematu brak jest informacji o zastosowaniu sieci neuronowych w modelowaniu procesów cieplnych zachodzących podczas przebiegu procesu kompostowania. Celowe wydaje się więc podjęcie próby opracowania neuronowego modelu omawianego procesu, bazującego na danych empirycznych pozyskanych w oparciu o eksperyment laboratoryjny. Modele neuronowe, wygenerowane na bazie zbiorów uczących pozyskanych z pomiarów wykonanych w trakcie badań empirycznych, może być w przyszłości pomocny w szeroko rozumianej praktyce rolniczej. W szczególności może stanowić narzędzie wspomagające procesy decyzyjne zachodzące w trakcie produkcji nawozów naturalnych.

Celem pracy było wytworzenie oryginalnego modelu neuronowego, przeznaczonego do estymacji ilości ciepła, możliwej do pozyskania w trakcie przebiegu procesu kompostowania. Założono, że proponowany model dedykowany będzie dla prognozowania ilości energii cieplnej, możliwej do uzyskania z konkretnej substancji organicznej. Będzie on pomocny przy podejmowaniu decyzji dotyczących wykorzystania energii odnawialnej w praktyce, np. w pracach związanych z projektowaniem inwestycji typu kompostownie, oczyszczalnie ścieków, składowiska odpadów itp. Wiedza o przewidywanej ilości ciepła generowanego podczas kompostowania może być wykorzystana m.in. w szeroko rozumianej produkcji rolniczej, jak np.: w szklarniach czy lokalnych sieciach ciepłowniczych.

2. Metodyka badawcza

Problem naukowy, którego rozwiązania podjęto się w tej pracy, wymaga sprawdzenia hipotezy, którą sformułowano następująco: modelownie neuronowe jest adekwatnym narzędziem do estymacji poziomu emisji ciepła generowanego w trakcie egzotermicznego procesu kompostowania wybranych substancji organicznych.

W trakcie wykonywania zaplanowanych zadań pojawiły się problemy cząstkowe, które sformułowano w postaci niżej przedstawionych pytań.

1. Które z parametrów charakteryzujących proces kompostowania są niezbędne dla poprawnego przewidywania ilości emitowanego ciepła?
2. Czy sztuczne sieci neuronowe są adekwatnym narzędziem predykcyjnym do estymacji ilości ciepła wydzielanego podczas tego procesu?
3. Jaka topologia sztucznych sieci neuronowych jest optymalna w procesie predykcji ilości traconego ciepła, generowanego w trakcie kompostowania?

Realizacja zadania przebiegała w kilku fazach, które wykonane zostały w następujących etapach:

- budowa stanowiska badawczego umożliwiającego przeprowadzenie procesu kompostowania w warunkach laboratoryjnych,
- przeprowadzenie serii doświadczeń (z różnym materiałem organicznym),
- akwizycja parametrów fizycznych charakteryzujących badany proces,

- przetworzenie danych empirycznych do postaci zbiorów uczących niezbędnych w procesie symulacji sztucznych sieci neuronowych,
- wstępne projektowanie oraz wytworzenie zbioru modeli neuronowych z wykorzystaniem pakietu *Statistica v.7.1*,
- dobór oraz selekcja zmiennych wejściowych
- testowanie oraz walidacja otrzymanych topologii neuronowych,
- wybór optymalnego modelu neuronowego.

Badania empiryczne

Do badania procesów cieplnych zachodzących w trakcie kompostowania wykorzystano obornik świński. Obornik pochodził z gospodarstwa hodowlanego Państwa Bartkowiaków, znajdującego się w podpoznańskim Batorowie (rys. 1.). Hodowla świń prowadzona jest tam w cyklu zamkniętym, w gospodarstwie znajduje się 1 knur, 20 macior, 40 prosiąt, 100 warchlaków, 50 tuczników. Rasa macior – Polska, Biała Zwistoucha (PBZ) oraz mieszańce z rasą Wielką Białą Polską (PBZ x WBP), knur jest rasy PBZ. Zwierzęta są przeznaczone na tucz. Zwierzęta karmione są:

- maciory luźne – 2,5% premiks, 32,5% otręby pszenne, 15% susz z wywaru gorzelnianego, 50% zboże,
- maciory karmiące – 4% premiks, 12% soja, 4% otręby pszenne, 80% zboże,
- prosięta – 4% premiks, 16% soja, 80% zboże,
- warchlaki – 3% premiks, 10% soja, 12% susz z wywaru gorzelnianego, 75% zboże,
- tuczniaki – 2,5% premiks, 17,5% susz w wywaru gorzelnianego, 80% zboże.

Obornik od macior, knura i prosiąt wywożony jest na przymę dwa razy w tygodniu. Pozostałe zwierzęta (warchlaki i tuczniaki) utrzymywane są na głębokiej ściółce, gdzie obornik usuwany jest po sprzedaży tuczników (po 4 miesiącach). Do ścielenia używana jest słoma pszenna ozima, pszenżyto ozime i mieszanki jare. W okresie pobierania obornika do badań wykorzystywana była słoma pszenna ozima. Dawka słomy dziennie wynosiła ok. 6 kg na dużą jednostkę przeliczeniową. Roczna produkcja obornika waha się w granicach 250 ton na rok. Do przeprowadzenia badań pobierano obornik od grupy zwierząt, na którą składały się warchlaki i tuczniaki hodowane na głębokiej ściółce.



Rys. 1. Pozyskanie obornika do przeprowadzenia procesu kompostowania

Fig. 1. Acquisition of manure for making the composting process

Do badań laboratoryjnych procesu kompostowania materiałów organicznych wykorzystywano czterokomorowy bioreaktor (rys. 2.) zaprojektowany i zbudowany na terenie Instytutu Inżynierii Rolniczej Uniwersytetu Przyrodniczego w Poznaniu.



Rys. 2. Bioreaktor do badania procesów rozkładu substancji organicznych
Fig. 2. Bioreactor for studying the processes of organic decomposition

Jest to reaktor samonagrzewający się. Każda z komór ma 165 litrów pojemności, a stosunek powierzchni do objętości wynosi 10,85 m²/m³. Ściany komór zaizolowane są za pomocą styropianu (warstwa 10 cm). Powietrze do każdej z komór doprowadzane jest przez cały okres trwania procesu za pomocą dmuchaw membranowych (Akwatech HiBlow HP10). Przepływ powietrza do komór regulowany jest z wykorzystaniem rotametu stołowego (Rotametr RP T 96 193) oraz zaworów.

Tab. 1. Fragment pliku danych wykorzystywanego do obliczeń strat ciepła
Table 1. Fragment of a data file used to calculate the heat loss

I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC
SM	Subst org	Subst mineralna	Qw [J/s]	Qw [kJ/dzień]	Wilgotność pow wlot	pas - Ciś cząstki pary wodnej w st nasyceni a [Pa]	pa - Ciś cząstki we pary wodnej [Pa]	ρ - Gęstość powietrza wilgotnego [kg/m ³]	m - strumień całkowity pow wilg [kg/h]	X - wilg bezwzgl masowa [kg/h]	mb - strumień powietrza suchego [kg/h]	I - entalpia właściwa powietrza wilgotnego [kJ/kg]	I - entalpia całkowita strumienia na wejściu [kJ/h]	pas - Ciś cząstki pary wodnej w st nasyceni a [Pa]	pa - Ciś cząstki we pary wodnej [Pa]	X - wilg bezwzgl masowa [kg/kg]	is - entalpia powietrza nasycycon ego [kJ/kg]	is - entalpia całkowite strumienia na wyjściu [kJ/h]	Straty ciepła przez konwekcje [kJ/dzień]	Straty ciepła przez konwekcje [kJ/dzień]
21,90	87,7	12,3	5,62	485,91	0,41	2485	1018,85	1,18158	0,00354475	0,0064	0,00352220	36,9636	0,13019	3778	0,02442	90,5045	0,31877	0,19	4,53	
24,27	86,5	11,5	28,12	2429,57	0,4	2337	934,8	1,18438	0,00355313	0,00587	0,00353240	34,9999	0,12363	17312	17312	0,13023	396,933	1,40213	1,28	30,88
24,27	86,5	11,5	32,76	2830,12	0,4	2485	994	1,18049	0,00354146	0,00624	0,00351949	36,8688	0,12976	23910	23910	0,19545	576,665	2,02956	1,90	45,80
23,96	87,9	12,1	41,04	3545,86	0,4	2337	934,8	1,18438	0,00355313	0,00587	0,00353240	34,9999	0,12363	36960	36960	0,36468	1037,16	3,66365	3,54	84,96
23,64	87,4	12,6	40,58	3506,46	0,4	2485	994	1,18169	0,00354508	0,00624	0,00352308	36,563	0,12681	36960	36960	0,36468	1037,16	3,65398	3,53	84,80
23,33	86,8	13,2	39,82	3440,79	0,4	2485	994	1,18169	0,00354508	0,00624	0,00352308	36,563	0,12681	35430	35430	0,3413	973,785	3,43072	3,30	79,19
23,33	86,8	13,2	39,82	3440,79	0,4	2485	994	1,18169	0,00354508	0,00624	0,00352308	36,563	0,12681	35430	35430	0,3413	973,785	3,43072	3,30	79,19
23,82	86,4	13,6	39,89	3453,93	0,43	2337	1004,91	1,18245	0,00354735	0,00631	0,00352908	36,5354	0,12879	32910	32910	0,31885	915,609	3,23608	3,11	74,66
24,32	86,0	14,0	39,75	3434,23	0,42	2337	991,54	1,18538	0,00356614	0,00617	0,00353435	35,4473	0,12528	33960	33960	0,31885	915,609	3,23608	3,11	74,66
24,81	85,6	14,4	38,30	3309,47	0,41	2485	1018,85	1,18158	0,00354475	0,0064	0,00352203	36,9636	0,13019	32530	32530	0,29989	861,412	3,03406	2,90	69,69
24,81	85,6	14,4	38,76	3348,86	0,41	2337	958,17	1,18427	0,00355282	0,00602	0,00353157	35,376	0,12493	32530	32530	0,29989	861,412	3,04214	2,92	70,01
24,81	85,6	14,4	38,76	3348,86	0,41	2195	899,95	1,18859	0,00356577	0,00585	0,00354574	33,4237	0,11851	31160	31160	0,28154	811,544	2,87752	2,76	66,22
24,27	85,6	14,4	39,06	3375,13	0,4	2195	878	1,19032	0,00357095	0,00551	0,00351139	32,865	0,11601	31160	31160	0,28154	811,544	2,88211	2,77	66,39
23,72	85,7	14,3	36,10	3119,04	0,4	2642	1056,8	1,1778	0,00353341	0,00664	0,00352043	38,4914	0,13511	29830	29830	0,26442	764,957	2,88807	2,55	61,20
23,18	85,7	14,3	36,48	3151,87	0,4	2485	994	1,18009	0,00354026	0,00624	0,00351829	36,9697	0,13007	29830	29830	0,26442	764,957	2,89134	2,56	61,47
22,64	85,7	14,3	35,64	3079,64	0,42	2485	1043,7	1,17946	0,00353839	0,00656	0,00351533	37,873	0,13314	29830	29830	0,26442	763,454	2,88379	2,55	61,22
22,09	85,7	14,3	35,26	3046,81	0,42	2485	1043,7	1,18147	0,00354441	0,00656	0,00352131	37,3643	0,13157	27330	27330	0,23392	681,844	2,40099	2,27	54,47
21,55	85,8	14,2	33,44	2889,22	0,4	2337	934,8	1,18438	0,00355313	0,00587	0,00353240	34,9999	0,12363	23910	23910	0,19545	576,665	2,03701	1,91	45,92
21,55	85,8	14,2	32,00	2764,45	0,41	2485	1018,85	1,18038	0,00354113	0,0064	0,00351860	37,2687	0,13113	22850	22850	0,18422	545,873	1,92071	1,79	42,95
21,62	85,4	14,6	26,60	2298,24	0,4	2337	934,8	1,18438	0,00355313	0,00587	0,00353240	34,9999	0,12363	15741	15741	0,1162	357,906	1,26427	1,14	27,38
21,70	85,0	15,0	28,42	2455,83	0,4	2485	994	1,18169	0,00354508	0,00624	0,00352308	36,563	0,12881	18146	18146	0,13789	418,187	1,47331	1,34	32,27
21,77	84,6	15,4	42,10	3637,79	0,43	2485	1068,55	1,18136	0,00354408	0,00672	0,00352903	37,7653	0,13295	40190	40190	0,14796	481,182	1,47509	4,03	96,63
21,85	84,2	15,8	32,22	2784,15	0,41	2485	1018,85	1,18158	0,00354475	0,0064	0,00352220	36,9636	0,13019	22850	22850	0,18422	545,873	1,92267	1,79	43,02
22,19	83,6	16,4	30,10	2600,29	0,4	2337	934,8	1,18276	0,00354829	0,00587	0,00352759	35,4063	0,1249	19917	19917	0,15469	464,64	1,63906	1,51	36,34
22,54	83,0	17,0	26,07	2252,28	0,43	2337	1004,91	1,18528	0,00355583	0,00631	0,00352908	35,8236	0,12658	15002	15002	0,10978	339,98	1,20132	1,07	25,79
22,88	82,4	17,6	24,62	2127,51	0,42	2485	1043,7	1,18147	0,00354441	0,00656	0,00352131	37,3643	0,13157	14293	14293	0,10373	323,025	1,13747	1,01	24,14
23,23	81,8	18,2	20,82	1799,19	0,4	2337	934,8	1,186	0,00355799	0,00587	0,00353723	34,5934	0,12236	10612	10612	0,07384	238,441	0,84342	0,72	17,31
23,23	81,8	18,2	19,00	1641,60	0,43	2337	1004,91	1,18406	0,00355219	0,00631	0,00352990	36,1287	0,12753	9582	9582	0,06692	215,658	0,76125	0,63	15,21
22,61	81,6	18,4	18,24	1575,94	0,42	2195	921,9	1,18849	0,00356475	0,00579	0,00354495	33,7765	0,11974	8639	8639	0,05882	195,088	0,69151	0,57	13,72
21,99	81,4	18,6	15,50	1339,55	0,4	2195	878	1,19032	0,00357095	0,00551	0,00351139	32,665	0,11601	6991	6991	0,04675	159,551	0,56863	0,45	10,81
40,09	81,8	18,2	9,12	787,97	0,41	2195	899,95	1,18859	0,00356577	0,00585	0,00354574	33,4237	0,11851	4491	4491	0,02925	106,008	0,37588	0,26	6,18
58,18	82,1	17,9	6,84	590,98	0,41	2337	958,17	1,18427	0,00355282	0,00602	0,00353157	35,376	0,12493	4004	4004	0,02594	95,4446	0,33707	0,21	5,09
76,27	82,5	17,5	5,85	505,61	0,41	2337	958,17	1,18306	0,00354919	0,00602	0,00352796	35,6809	0,12588	3778	3778	0,02442	90,5045	0,3193	0,19	4,84
21,90	87,7	12,3	7,90	682,91	0,41	2485	1018,85	1,18158	0,00354475	0,0064	0,00352220	36,9636	0,13019	4491	4491	0,02325	87,008	0,49784	0,32	7,78
18,19	89,5	10,5	33,44	2899,22	0,4	2337	934,8	1,18438	0,00355313	0,00587	0,00353240	34,9999	0,12363	23910	23910	0,19545	576,665	2,1602	2,55	61,23
18,19	89,5	10,5	36,08	3289,77	0,4	2485	994	1,18049	0,00354146	0,00624	0,00351949	36,8688	0,12976	3253	3253	0,02091	126,452	0,5934	0,42	10,09
19,90	88,7	11,3	42,56	3677,18	0,4	2337	934,8	1,18438	0,00355313	0,00587	0,00353240	34,9999	0,12363	40190	40190	0,14796	481,182	1,47509	5,40	129,59
21,61	87,9	12,1	41,34	3572,12	0,4	2485	994	1,18169	0,00354508	0,00624	0,00352308	36,563	0,12715	38550	38550	0,39021	1106,3	3,19676	5,03	120,60
23,32	87,2	12,8	40,58	3506,46	0,41	2485	1018,85	1,18158	0,00354475	0,0064	0,00352220	36,9636	0,13019	36960	36960	0,36468	1037,16	3,67876	4,70	112,73
23,32	87,2	12,8	41,34	3572,12	0,4	2485	994	1,18169	0,00354508	0,00624	0,00352308	36,563	0,12715	38550	38550	0,39021	1106,3	3,19676	5,03	120,60
23,23	86,9	13,1	40,74	3519,59	0,43	2337	1004,91	1,18245	0,00354735	0,00631	0,00352908	36,5354	0,12712	36960	36960	0,36468	1037,16	3,67476	4,70	112,87
23,13	86,5	13,5	40,51	3499,89	0,42	2337	991,54	1,18538	0,00356614	0,00617	0,00353435	35,4473	0,12674	35430	35430	0,3413	973,785	3,48893	4,42	106,13
23,03	86,2	13,8	38,30	3309,47	0,41	2485	1018,85	1,18158	0,00354475	0,0064	0,00352220	36,9636	0,13019	32530	32530	0,29989	861,412	3,04542	3,87	92,92

W celu zróżnicowania warunków kompostowania każda z komór posiadała inną wartość przepływu, stosowano 2, 3, 4 i 5 l/min. Aby lepiej rozprowadzać powietrze w kompostowanej masie komory wyposażone są w ażurową podłogę. Zastosowanie tego rozwiązania pozwala również na gromadzenie odcieków spływających do zbiorników pod komorą. Do obniżenia temperatury gazów wylotowych oraz usunięcia z nich pary wodnej stosuje się kolumny z węzownią, w których medium chłodniczym jest zimna woda. Skroplona para wodna gromadzona jest w zbiornikach umożliwiających pomiar jej objętości i pobranie próbek do dalszych analiz chemicznych.

Woda w postaci kropli usuwana była również ze środka bioreaktora z wykorzystaniem systemu okapów i rynienek. Było to niezbędne dla uniknięcia efektu skraplania się pary wodnej na pokrywie i jej powrotu do kompostowanej masy. Zaburzałoby to w znaczący sposób bilans energetyczny kompostowania (ciepło zużywane byłoby na wielokrotne odparowywanie tej samej wody, co nie występuje w warunkach rzeczywistych).

Modelowanie neuronowe

Laboratoryjne odtworzenie warunków naturalnych procesu kompostowania oraz zastosowanie opisanej wyżej aparatury pomiarowej umożliwiło zgromadzenie bazy danych empirycznych opisujących badany proces. Wyniki pomiarów były podczas doświadczeń zapisywane w arkuszu programu Excel. Następnie dane te zostały wykorzystane do obliczeń strat ciepła i zapisane w czterech plikach *.xls. Każda seria badań zapisana została w oddzielnym pliku (tab. 1).

Każdy z plików arkusza kalkulacyjnego został zaimportowany do oprogramowania *Statistica v. 7.1* i przetworzony na plik danych z rozszerzeniem *.sta. Następnie, za pomocą narzędzia dostępnego w pakiecie *Statistica*, scalono pliki według nazw zmiennych. Wynikiem był zbiór o nazwie „komp obronik” składający się z 616 przypadków i posiadający 12 zmiennych: 10 wejściowych oraz 2 wyjściowe (rys. 3). W celu uniknięcia problemu redundancji danych [1], na podstawie doświadczeń własnych oraz źródeł literaturowych wytypowano zmienne reprezentatywne, które mają istotny wpływ na przebieg procesu kompostowania (tab. 2).

Tab. 2. Zmienne zbioru danych „komp obronik”
Tab. 2. Variable data set “comp manure”

Lp.	Nazwa zmiennej	Oznaczenie	Jednostka
1.	Czas trwania procesu	Czas	h
2.	Temperatura wewnątrz komory	Temp	°C
3.	Temperatura otoczenia	Temp otocz.	°C
4.	Zawartość tlenu w gazach wylotowych	O ₂	%
5.	Zawartość metanu w gazach wylotowych	CH ₄	%DGW
6.	Zawartość CO ₂ w gazach wylotowych	CO ₂	%
7.	Przepływ	V	l h ⁻¹
8.	Sucha substancja	SM	%
9.	Substancje organiczne	Subst org.	%
10.	Substancje mineralne	Subst min.	%
11.	Straty ciepła przez przenikanie	qw	kJ dzień ⁻¹
12.	Straty ciepła przez konwekcję	qk	kJ dzień ⁻¹

Zmiennymi wyjściowymi, czyli oczekiwanymi odpowiedziami sieci, były straty ciepła generowane w trakcie procesów przenikania qw oraz konwekcji qk. Wykorzystu-

jąc nazewnictwo używane w pakiecie *Statistica* zarówno zmienne wejściowe jak i wyjściowe można przypisać do grupy tzw. zmiennych ciągłych – czyli wartości liczbowych, będących najczęściej wynikiem pomiarów.

Ze zbioru danych empirycznych „komp obronik” zostały wydzielone dwa podzbiory α i β . Podzbiór α składa się z 596 przypadków, które były wykorzystywane do uczenia, walidacji i wstępnego testowania sztucznych sieci neuronowych. Podzbiór β składa się z 20 losowo wybranych przypadków, które nie były używane przy budowie sieci i zostały wykorzystane do ostatecznego przetestowania jakości otrzymanego modelu neuronowego. Wykorzystanie podzbioru β ma za zadanie symulację warunków praktycznych, gdy na wejścia stworzonego modelu neuronowego zostają podane nowe wartości zmiennych. Pomoże to ustalić, czy otrzymany model nie uległ przeuczeniu. Zbiór α został losowo podzielony na trzy podzbiory (w skali 2:1:1): uczący U: 298 przypadków, walidacyjny W: 149 przypadków i testowy T: 149 przypadków. Podzbiór uczący jest wykorzystywany przez symulator sieci neuronowych *Statistica v.7.1* do przeprowadzenia uczenia modelu sieci. Kolejny podzbiór – walidacyjny służy do sprawdzenia jakości sieci – już podczas jej uczenia. Jest to istotne dla uniknięcia przeuczenia sieci i dobrej generalizacji wiedzy. Ostatni z podzbiorów – testowy nie bierze udziału w wyżej wymienionych procesach, jest to ostateczne narzędzie pozwalające ocenić jakość otrzymanego modelu. Wybrano opcje losowego przypisywania przypadków do podzbiorów dla każdej z nowo projektowanej sieci.

Podczas uczenia przypadki zostały poddawane wstępnemu przetwarzaniu – tzw. preprocessingowi. Polega on na przeskalowaniu wszystkich wielkości do wartości odpowiednich dla sieci neuronowej. W badaniach wykorzystano liniową funkcję *minimax* [6], która największej wartości liczbowej danej zmiennej przypisuje wartość 1, a najmniejszej 0. Pozostałe przypadki przyjmują odpowiednie wartości pomiędzy tymi granicami.

	1 Czas	2 Temp	3 Temp otocz.	4 O ₂	5 CH ₄	6 CO ₂	7 V	8 SM	9 Subst org	10 Subst min	11 qw	12 qk
597	206,5	55	20	17,97	1608,83	1,95	4	20,83	83,83	16,17	2298,24	36,50
598	216,0	52	21	18,46	1622,71	1,95	4	20,83	83,83	16,17	2042,15	30,37
599	229,5	47	20	17,97	1622,71	1,95	4	20,77	83,25	16,75	1772,93	23,00
600	232,3	49	20	17,78	1622,71	1,95	4	20,73	82,95	17,05	1851,72	25,07
601	235,0	50	21	17,59	1622,7	1,95	4	20,70	82,66	17,34	1930,52	27,15
602	259,0	68						20,63	82,08	17,92		
603	311,0	54						20,57	81,49	18,51		
604	318,5	52						20,74	81,66	18,34		
605	326,0	50	20	18,53	1622,71	0,97	4	20,92	81,84	18,16		
606	350,0	42	20	19,09	1594,95	0,84	4	21,28	82,18	17,82		
607	354,5	41	21	19,12	1594,95	0,84	4	21,63	82,52	17,48	1339,95	15,87
608	378,5	38	20	19,15	1594,95	0,84	4	21,99	82,87	17,13	1208,22	13,26
609	383,5	38	20	19,03	1594,95	0,84	4	21,99	82,87	17,13	1195,08	13,15
610	388,5	38	20	18,91	1594,95	0,84	4	21,99	82,87	17,13	1181,95	13,05
611	402,5	38	19	19,05	1581,07	0,97	4	23,79	81,68	18,32	1247,62	13,38
612	425,5	37	19	19,12	1594,95	0,84	4	25,69	80,50	19,60	1208,22	12,68
613	453,0	36	19	19,17	1591,48	0,90	4	24,74	80,32	19,68	1129,42	11,83
614	480,5	35	19	19,22	1588,01	0,97	4	23,89	80,15	19,85	1050,62	10,99
615	502,5	33	20	19,19	1581,07	0,97	4	22,18	79,79	20,21	853,63	9,29
616	523,0	33	20	19,22	1567,19	0,97	4	20,48	79,44	20,56	833,93	9,25

Rys. 3. Fragment zbioru uczącego w programie *Statistica v.7.1*
Fig. 3. Fragment of teaching file in the *Statistica v.7.1* software

W związku z występowaniem dwóch zmiennych wyjściowych, przetestowano i porównano następujące struktury sieci neuronowych:


- **SN1** – sieć z 10 zmiennymi wejściowymi i 1 zmienną wyjściową qw,
- **SN2** – sieć z 10 zmiennymi wejściowymi i 1 zmienną wyjściową qk,
- **SN3** – sieć z 10 zmiennymi wejściowymi i 2 zmiennymi wyjściowymi qw i qk.

W badaniach skupiono się na trzech typach sieci: liniowych, MLP (ang. *MultiLayer Perceptron*) oraz RBF (ang. *Radial Basis Function*). Przy rozwiązywaniu problemów regresyjnych sieci liniowe, mimo swojej nieskomplikowanej budowy, często są dobrym modelem wstępnym, będącym odnośnikiem dla porównania wyników uzyskanych za pomocą bardziej rozbudowanych modeli nieliniowych. Perceptrony wielowarstwowe są jednym z najpopularniejszych i najlepiej zbadanych rodzajów jednokierunkowych sieci neuronowych. Charakteryzują się one szerokim wachlarzem zastosowań oraz dysponują sporym zasobem efektywnych algorytmów uczenia. W przeprowadzonych analizach wykorzystywano perceptrony z jedną warstwą ukrytą. Złożoność taka okazuje się być wystarczającą dla rozwiązania wielu problemów, minimalizując przy tym niebezpieczeństwo przeuczenia sieci w trakcie jej optymalizacji [4]. Kolejnym typem sieci, testowanym w niniejszej pracy, była sieć o radialnych funkcjach bazowych. W odróżnieniu od globalnych modeli typu MLP, sieci typu RBF są przykładem realizacji aproksymacji lokalnej, gdzie poszczególne neurony generują funkcje zmieniające się radialnie wokół wybranych, lokalnych centrów oraz posiadają wartości niezerowe tylko w otoczeniu tych centrów. Badanie różnych topologii neuronowych pozwoliło na porównanie uzyskanych wyników, a następnie na wskazanie optymalnych topologii neuronowych.

3. Wyniki badań

Po wykonaniu serii symulacji komputerowych wybrano następujące struktury neuronowe, które wykazały się najlepszą efektywnością jako instrumenty predykcyjne:


- **SN1:** sieć typu MLP o topologii 10 – 6 – 1 (rys. 4)



Rys. 4. SN1: sieć typu MLP

Fig. 4. SN1: neural network MLP type


- **SN2:** sieć typu MLP o topologii 10 – 9 – 1 (rys. 5)



Rys. 5. SN2: sieć typu MLP

Fig. 5. SN2: neural network MLP type

- **SN3:** sieć typu MLP o topologii 10 – 14 – 2 (rys. 6)



Rys. 6. SN3: sieć typu MLP

Fig. 6. SN3: neural network MLP type

Sieć **SN1** przewiduje straty ciepła przez przenikanie. Jest ona perceptronem wielowarstwowym uczonym przez 100 epok za pomocą algorytmu wstecznej propagacji błędów, a następnie douczanym przez 60 epok algorytmem gradientów sprzężonych.

Sieć **SN2** określa straty ciepła w wyniku konwekcji. Jest ona perceptronem wielowarstwowym uczonym przez 100 epok za pomocą algorytmu wstecznej propagacji błędów, a następnie douczanym przez 182 epok algorytmem gradientów sprzężonych.

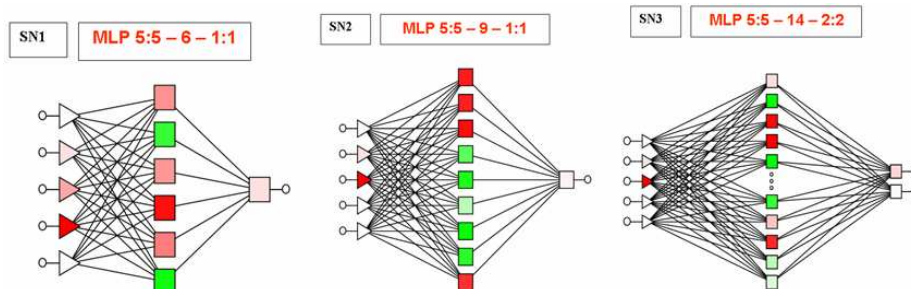
Sieć **SN3** posiada dwa wyjścia (dla obu strat ciepła). Jest perceptronem wielowarstwowym uczonym przez 100 epok za pomocą algorytmu wstecznej propagacji błędów, a następnie douczanym przez 176 epok algorytmem gradientów sprzężonych.

W tab. 3 przedstawiono parametry regresyjne wszystkich otrzymanych modeli. Wyniki są ukazane dla trzech podzbiorów, wykorzystywanych do tworzenia sieci neuronowej. Wybrane modele charakteryzowały się najmniejszym poziomem ilorazu odchyłeń standardowych. Jego zbliżona do zera wartość świadczy o wysokiej jakości wygenerowanych sieci neuronowych. Zakres tego współczynnika we wszystkich sieciach zawierał się w granicach 0,02-0,09. Każdy z podzbiorów: uczący, walidacyjny i testowy zbudowany był z przypadków dobranych na drodze losowania. Wartości poszczególnych parametrów statystyk regresyjnych osiągały porównywalne wartości dla wszystkich trzech podzbiorów, co pozwala wnioskować o dobrej jakości wytworzonych modeli predykcyjnych. Współczynnik korelacji, określający współzależność pomiędzy poszczególnymi zmiennymi wejściowymi a zmienną wyjściową, osiągnął dla wszystkich otrzymanych modeli wysoką wartość, rzędu 0,989-0,999.

Po przeprowadzeniu analizy wrażliwości wytworzonych sieci na poszczególne zmienne reprezentatywne (zgodnie ze standardowymi procedurami zaimplementowanymi w pakiecie *Statistica*) oszacowano poziom istotności wszystkich 10 parametrów wejściowych modeli neuronowych na jakość generowanej predykcji. Pozwoliło to na optymalizację struktury wytworzonych sztucznych sieci neuronowych. Dla modelu SN1 najważniejszymi zmiennymi wejściowymi okazały się: temperatura, temperatura wewnątrz bioreaktora, temperatura otoczenia, O₂, CO₂ oraz czas. Dla modeli SN2 i SN3 tymi wielkościami były: temperatura wewnątrz bioreaktora, O₂, CO₂, czas oraz prędkość przepływu gazów. Zredukowane modele neuronowe przedstawiono na rys. 7.

Tab. 3. Statystyki regresyjne otrzymanych modeli neuronowych
 Tab. 3. Regression statistics of obtained neural models

	Podzbiory					
	uczący		walidacyjny		testowy	
	SN1					
Średnia	2171,355		2358,012		2283,604	
Odchylenie standardowe	1135,063		1017,673		1011,784	
Średni błąd	0,025		-0,154		-0,419	
Odchylenie błędu	2,613		2,292		3,146	
Średni błąd bezwzględny	1,771		1,661		1,890	
Iloraz odchyień	0,002		0,002		0,003	
Korelacja	0,989		0,988		0,988	
	SN2					
Średnia	49,46440		46,72535		46,76018	
Odchylenie standardowe	39,11638		37,21028		34,70162	
Średni błąd	-0,31301		0,00355		-0,22513	
Odchylenie błędu	2,64466		2,23729		3,05116	
Średni błąd bezwzględny	1,68359		1,52336		1,76783	
Iloraz odchyień	0,06761		0,06013		0,08793	
Korelacja	0,997		0,998		0,996	
	SN3					
Wyjście sieci	qw	qk	qw	qk	qw	qk
Średnia	2188,3	46,809	2327,6	48,792	2280,0	50,002
Odchylenie standardowe	1119,5	38,540	983,70	34,968	1082,7	38,150
Średni błąd	0,208	-0,410	-3,145	0,2346	0,183	-0,498
Odchylenie błędu	21,382	3,2106	18,270	2,4495	22,900	3,4712
Średni błąd bezwzględny	15,731	2,2955	14,452	1,9480	17,273	2,4232
Iloraz odchyień	0,019	0,0833	0,019	0,0700	0,021	0,0909
Korelacja	0,999	0,9965	0,999	0,9970	0,999	0,9950



Rys. 7. Zredukowane sieci typu MLP
 Fig. 7. Reduced neural networks MLP type

4. Wnioski

- Wyniki badań potwierdzają hipotezę, że modelownie neuronowe może być wykorzystywane jako efektywny instrument do szacowania straty energii cieplnej powstającej w trakcie procesu kompostowania.
- Wykorzystanie technik wspomagających proces doboru cech pozwoliło na redukcję liczby reprezentatywnych zmiennych wejściowych do pięciu, a następnie określenie ich wpływu na jakość wytworzonego modelu neuronowego.
- Najistotniejsze zmienne wejściowe zbudowanych modeli neuronowych to w kolejności: temperatura wewnątrz bioreaktora oraz zawartość O₂ i CO₂ w gazach wylotowych.
- Optymalną topologią sztucznej sieci neuronowej do estymacji generowanego w trakcie kompostowania ciepła okazała się sieć typu MLP (perceptron wielowarstwowy) o strukturze: 5 - 14 - 2.
- Wytworzony model neuronowy może być pomocny w trakcie planowania oraz budowy stanowisk przeznaczonych do kompostowania nawozów naturalnych.

5. Literatura

- [1] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu 2008.
- [2] Burton C. H., Turner C.: Manure management. Treatment strategies for sustainable agriculture 2nd edition. Silsoe Research Institute, Bedford 2003.
- [3] Chan C. W., Huang G. H.: Artificial intelligence for management and control of pollution minimization and mitigation processes. Engineering applications of artificial intelligence, 2003, vol. 16, s. 75-90.
- [4] Grzeszczyk T. A.: Sztuczna inteligencja we wspomaganiu procesu prognozowania w przedsiębiorstwie. Statystyka i Data Mining w badaniach naukowych. StatSoft Polska, Kraków 2005.
- [5] Kosiński R.: Sztuczne sieci neuronowe, dynamika nieliniowa i chaos. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
- [6] Marciniak A., Korbicz J., Kuś J.: Wstępne przetwarzanie danych. Biocybernetyka i inżynieria biomedyczna, tom 6, Sieci neuronowe – praca zbiorowa, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
- [7] Ozkaya B., Demir A., Bilgili M.S.: Neural network prediction model for the methane fraction in biogas from field-scale landfill bioreactors. Environmental Modelling & Software, 2007, vol. 22, s. 815-822.
- [8] Romaniuk W., Overby T.: Magazynowanie nawozów naturalnych. Poradnik / Praca zbiorowa. Warszawa: Instytut Budownictwa, Mechanizacji i Elektryfikacji Rolnictwa; Duńskie Służby Doradztwa Rolniczego 2004.