

ВИСША АТЕСТАЦИОННА КОМИСИЯ  
СПЕЦИАЛИЗИРАН НАУЧЕН СЪВЕТ ПО  
“АВТОМАТИКА И СИСТЕМИ ЗА УПРАВЛЕНИЕ”

**н. с. II ст. инж. Елена Йорданова Чорукова**

**НЕВРОННО И ХИБРИДНО  
МОДЕЛИРАНЕ И ОПТИМИЗАЦИЯ НА  
БИОТЕХНОЛОГИЧНИ ПРОЦЕСИ**

**А В Т О Р Е Ф Е Р А Т**

**на дисертация**

**за присъждане на образователната и научна степен “доктор”  
по научна специалност 02.21.12 “Биоавтоматика”**

**Научен ръководител: ст.н.с. II ст. д-р Иван Симеонов**

**Рецензенти: проф. д-тн Стоян Цонков  
ст. н.с. II ст. д-р Силвия Попова**

**СОФИЯ**

**2009**

Дисертационния труд е обсъден и насочен за защита пред Специализирания научен съвет по “Автоматика и системи за управление” при ВАК от съвместно заседание на семинара “Приложна микробиология и микробни биотехнологии” към Института по микробиология “Стефан Ангелов” – БАН и на секция “Моделиране и оптимизация на биопроцесни системи” към ЦЛБМИ “Проф. Иван Даскалов” – БАН.

Защитата на дисертационния труд ще се състои на 26.05.2009 г. от ..... ч. в зала 2200 на Технически университет – София на заседание на СНС по “Автоматика и системи за управление” при ВАК.

Материалите по защитата са на разположение на интересуващите се в канцеларията на Факултет Автоматика, стая 2325, Технически университет – София.

Автор: н.с. II ст. Елена Йорданова Чорукова

**Заглавие: Невронно и хибридно моделиране и оптимизация на биотехнологични процеси**

## ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

**Актуалност:** Биотехнологията е наука, развиваща се интензивно в последните 30 години. Биотехнологичните процеси (БТП) са предмет на описание и моделиране с различни подходи в последните 20 години. Поради голямата им сложност все още има нерешени проблеми и създаването на адекватни модели на БТП за различни цели продължава да бъде актуална задача.

Моделите на БТП са изключително разнообразни в зависимост от целите на моделирането. Детерминистичното моделиране на някои изключително сложни процеси не дава задоволителни резултати. В такъв случай се търсят алтернативни методи на моделиране, включващи модели с елементи на изкуствен интелект, различни типове хибридни модели и др. Измежду подходите на т.нар. „изкуствен интелект” най-широко разпространение при моделирането получи апаратът на изкуствените невронни (ИНМ) мрежи поради добрата си приложимост за решаване на задачи за моделиране на сложни нелинейни обекти. В последните години бяха публикувани и дискутирани някои предложения за хибридни модели, с цел да се комбинират аналитичните предварителни знания за процеса с обучаващите способности на ИНМ. Някои автори показват, че т.нар. „хибриден подход” има предимства в сравнение с чисто невронния подход.

Съществена част при моделирането на БТП е оценяването на неизмеримите им променливи. Диференциално-алгебричния метод за идентифицируемост и наблюдаемост на динамични обекти е нов и актуален метод. Интересно е приложението на този подход при БТП.

Микробните БТП са изключително сложни процеси, трудни за моделиране. Ето защо са актуални въпросите, свързани с прилагането на апарата на ИНМ за моделиране на основните типове микробни БТП.

Вътреклетъчният ензим супероксид дисмутаза (СОД) от фунгалният щам *H. lutea* 103, от Микологичната сбирка на Института по микробиология „Ст. Ангелов” – БАН е изключително важен за човешкия организъм като една от най-важните линии на ензимната антиоксидантна система. Биосинтезът му е изключително сложен. Моделирането му е нелека и изключително актуална задача. До сега не са ни известни модели на този процес. Поради тези причини той е избран за моделиране с апарата на ИНМ като представител на периодичните и полупериодични процеси.

Анаеробното разграждане на органични отпадъци (АРОО) е широко разпространен и сложен процес с нарастващо значение. За това свидетелстват провежданите се на всеки три години световни конгреси по анаеробно разграждане. Неговата важност се обуславя от ролята му като източник на енергия и пречистващите му способности. Всичко това прави процеса актуален и моделирането му с различни подходи изключително интересно. Поради тези причини той е избран за обект на работа при моделирането с ИНМ на непрекъснати процеси.

Въз основа на така откритите проблеми за **основна цел на дисертационния труд** се определя изследването на възможностите на апарата на изкуствените невронни мрежи за моделиране и оптимизация на основните три типа микробни БТП: периодичен, полупериодичен и непрекъснат.

**Публикации и апробация на резултатите в дисертационния труд.** Основните резултати в дисертационния труд са отразени в 8 публикации: 4 в специализирани списания и 4 на международни конференции, 3 от които проведени в България и една в чужбина.

**Технически данни:** Дисертационният труд е в обем от 149 страници: въведение, пет глави, приноси по дисертационния труд, авторски публикации по темата и списък на използваната литература от 207 литературни източника. Съдържа 104 фигури, 48 таблици и 130 формули. В автореферата е използвано номериране на фигурите, таблиците и формулите, съответстващо на номерирането в дисертационния труд.

## КРАТКО СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

### Глава 1. Литературен обзор

Въз основа на представения в дисертацията литературен обзор и анализ на регистрираните до сега резултати могат да се направят следните по-важни изводи:

Създаването на модели на различни БТП е съществена част от изучаването, оптимизацията, автоматизацията и управлението им. Микробните БТП се характеризират с изключителна сложност, за това моделирането им е трудна задача. Срещат се редица важни микробни БТП, за които съществуващите математически модели не са достатъчно изчерпателни или дори такива не съществуват изобщо. За такива процеси задачата за създаване на адекватни и приложими за изследване, оптимизация и управление модели е много важна. Това обуславя актуалността на моделирането на тези процеси.

Поради свойствата им на универсален апроксиматор на нелинейни зависимости ИНМ са все по-разпространен метод за моделиране. Това прави този апарат актуален и интересен за трудни за моделиране процеси. БТП са съществено нелинейни и следователно предимствата на ИНМ за моделиране на нелинейни динамични системи могат да доведат до добри резултати. Приложенията на ИНМ за моделиране на различни БТП са все по-често срещани в научната литература. Липсва обаче опит за системно моделиране на трите основни типа микробни БТП – периодични, полупериодични и непрекъснати, както и сравнение на получените резултати от такова моделиране. Интересна задача би било да се изследват възможностите, трудностите, предимствата и недостатъците на апарата на ИНМ при моделиране на микробни БТП от гореспоменатите три основни типа.

Често срещано е използването на ИНМ в комбинации с други математически апарати, което води до получаването на хибридни модели. Разработени са хибридни модели на някои БТП, като получените резултати са обнадеждаващи. Все още недостатъчно са изследванията, в които разработените хибридни модели на БТП са комбинация от апарата на ИНМ и класическите модели от детерминистичен тип. Като една много добра алтернатива, интересна би била задачата да се изследват възможностите за такова хибридно моделиране на тези класове БТП, при които невронното моделиране не е дало задоволителни резултати.

Съществена част при разработката на невронни модели е обучението. С колкото повече и по-качествени данни за развитието на процеса се разполага, толкова по-добро е обучението и съответно по-пълни и изчерпателни са моделите. Характерна особеност за редица БТП е недостатъчната информация под формата на качествени данни за процеса. Причина за това е неналичието на сензори и методи за измерване на основните променливи, характеризиращи процесите. Една възможна алтернатива за решаване на този проблем е разработката на наблюдатели (софтуерни сензори), резултатите от които биха могли да се използват като входни данни за обучение на невронните

модели. Тази нова качествена информация за динамиката на основните величини на процесите може значително да подобри моделите.

Диференциално-алгебричния метод дава резултати при редица обекти. Той е все по-широко използван подход за анализ на биологични обекти, за което свидетелства провеждането вече на три конференции по алгебрична биология през 2005, 2007 и 2008 години, и предстоящата такава през 2009 година. Това обуславя прилагането на подхода в настоящия дисертационен труд за разработка на нови наблюдатели.

В научната литература се срещат приложения на ИНМ за моделиране на процеси за пречистване на околната среда и за моделиране на ензимни процеси. За представител на периодичното и полупериодично култивиране е избран процесът за аеробно получаване на вътреклетъчния ензим СОД от фунгалният щам *H. lutea* 103. Моделирането на непрекъснатото култивиране е направено за процеса на АРОО.

Въз основа на извършения анализ и направените изводи за основна **цел на дисертационния труд** се определя изследването на възможностите на апарата на изкуствените невронни мрежи за моделиране и оптимизация на основните три типа микробни БТП:

1. Периодичен – с представител процес за биосинтез на вътреклетъчния ензим супероксид дисмутаза.
2. Полупериодичен – с представител процес за биосинтез на вътреклетъчния ензим супероксид дисмутаза.
3. Непрекъснат – с представител процес за анаеробно разграждане на органични отпадъци.

За изпълнение на целта са формулирани следните **задачи**:

1. Разработване на модел на кинетиката на растежа и биосинтеза на вътреклетъчния ензим СОД с използване апарата на изкуствените невронни мрежи при периодично култивиране на *H. lutea* 103 с включване на разтворен кислород като управляващ вход.
2. Разработване на модел на кинетиката на растежа и биосинтеза на вътреклетъчния ензим СОД с използване апарата на изкуствените невронни мрежи при полупериодично култивиране на *H. lutea* 103 с включване на глюкоза като лимитиращ субстрат.
3. Разработване на модели на непрекъснат процес на АРОО с използване апарата на изкуствените невронни мрежи за единичен биореактор и за каскада от два биореактора.
4. Изследване наблюдаемостта и синтез на наблюдатели на някои основни променливи за процеса на АРОО, които могат да бъдат използвани за обучение на невронни модели.
5. Разработване на оптимизационни профили на периодичен и полупериодичен процес за биосинтеза на вътреклетъчния ензим СОД при управляващи входове разтворен кислород и количество на подхранващата глюкоза.

## **Глава 2. Експериментални изследвания**

В Институтът по микробиология „Ст. Ангелов” – БАН са проведени множество планирани експерименти за трите основни типа БТП, предмет на разглежданията в дисертационния труд – периодичен, полупериодичен и непрекъснат.

## **2.1. Периодичен и полупериодичен процес за получаване на ензим СОД**

Всички експерименти, разгледани в дисертационния труд, са извършени съвместно с колектива от секция “Микология”. Използван е щам *H. lutea* 103, продуцент на Cu/Zn – съдържаща СОД. Щамът се поддържа на бирен агар с рН 6.3 при 4°C. Използвани са лабораторни биореактори Biotec, Sweden с общ обем 15-L (работен обем 12-L) и 3-L лабораторен биореактор АБР-09. Биореакторите са снабдени с автоматични системи за измерване и поддържане на рН, температура и разтворен кислород.

За периодичния процес под планирани експерименти се разбират организирани експерименти с планирани подходящи начални условия за протичане на процеса (концентрации на субстрат и биомаса в биореактора) и подходящи нива на поддържане на разтворен кислород в биореактора по време на процеса.

Първоначално са проведени четирикратно повтарящи се експерименти с продължителност 132 часа, без измерване на разтворен кислород. Всеки от тях е осъществен в 3 или 5 паралелни колби. Данните са за концентрация на биомаса, концентрация на лимитиращ субстрат (глюкоза) и концентрация на СОД.

Впоследствие са проведени два типа експерименти с измерване на разтворен кислород в 3-L и 12-L биореактори, при температура 30°C за 120 часа всеки експеримент:

- Процес с измерване и без регулиране на разтворен кислород, където само се измерва разтворен кислород. Тези експерименти са проведени с цел проверяване на възможността да бъде използван този лесно измерим параметър като източник на информация за концентрациите на белтък, биомаса и ензим в биореактора. Извършени са седем последователни експеримента (три в 12-L и четири в 3-L биореактор).
- Процес с измерване и регулиране на разтворен кислород. Аерацията и/или скоростта на бъркачката се регулират за поддържане на различни нива (20, 35, 50 или 60% кислородно насищане в биореактора). В 3-L биореактор са проведени общо седем експеримента – по два за кислородни нива 20, 35 и 50% и един при 60%.

За полупериодичния процес под планирани експерименти се разбират организирани експерименти с планирано подходящо подхранване с лимитиращия субстрат глюкоза в биореактора по време на процеса.

Проведени са експерименти на 12-L биореактор оборудван със система за мониторинг на рН и автоматична система за мониторинг и управление на разтворен кислород. За зареждане на културата в биореактор, 800 ml от зародишната среда е инокулирана в 12-L биореактор, съдържащ 7.2 L среда. Културата расте при 30°C за 72 часа. Първият експеримент е базов периодичен процес без добавяне на допълнителна глюкоза в биореактора. Следващите 10 експеримента са полупериодични процеси при подхранване с глюкоза в концентрации съответно 0.75, 1.0, 1.5, 2.0 и 2.5 g/L. Подхранването започва в 12-ия час от инокулацията и продължава до края на процеса в интервал от 3 или 4 часа.

## **2.2. Непрекъснат процес за анаеробно разграждане на органични отпадъци**


За целите на дисертационния труд са проведени многобройни планирани експериментални изследвания на процеса на анаеробно разграждане. Използвана са

лабораторните биогазови инсталации на Института по микробиология „Ст. Ангелов” – БАН при различни органични отпадъци от животновъдството, хранително-вкусовата промишленост и пречиствателните станции на отпадни води.

Под планирани експерименти в случая се разбират организирани експерименти, проведени с изпитателните входни въздействия стъпалвиден сигнал и делта функция (импулс). Тези сигнали са известни от теорията на автоматичното управление като добри при линейни системи. Това доведе до предположението че могат да бъдат изследвани и в нелинейния случай. Подобен подход се среща и в литературните източници. Въпреки силната нелинейност на характеристиките на разглежданите процеси, изследваните входни въздействия се оказаха приложими и дадоха интересни и използваеми резултати, подходящи за моделиране на процесите.

За целите на моделиране и идентификация на процеса са формирани подходящи входни въздействия (стъпални и импулсни) с глюкоза и ацетат по съответните управляващи входове. Експерименталната установка е показана на Фиг. 4, където: 1 – анаеробен биореактор, 2 – двигател с бъркачка, 3 – разходомер на биогаз, 4 – подгряваща система, 5 – перисталтична помпа, 6 – газхолдер, 7 – електронен блок, 8 – газов хроматограф, 9 – газова горелка, 10 – ватмер, 11 – персонален компютър, 12 – принтер. Непрекъснато се измерват скоростта на разреждане, добивът на биогаз, концентрацията на ацетат в биореактора и ХПК на входа и на изхода.

Експериментите са провеждани едновременно в четири биореактора с обем 1 L, и 2 L. Скоростта на разбъркване е поддържана постоянна в диапазона  $\omega = 150\text{--}200\text{ 1/min}$ . В биореакторите е поддържана постоянна температура  $t^0 = 34^\circ\text{C}$ , pH в диапазона 6.3–8.5. Ежедневно се отливат и доливат такива количества от субстрати, които да съответстват на скорости на разреждане  $D = 0.025 \div 0.125\text{ day}^{-1}$




Фиг. 4. Експериментална установка

Проведени са експерименти при различни скорости на разреждане, както и с импулсно и стъпаловидно подаване на глюкоза и ацетат. Едновременно с това са проведени контролни анализи на субстратите за съдържание на органични вещества (ХПК), амониев азот (по Кейлдал), летливи мастни киселини (ацетат и пропионат), които служат за качествена оценка за хода на процеса.

Проведени са лабораторни експерименти на процеса за АРОО при мезофилна температура от  $34^\circ\text{C}$  в каскада от два анаеробни биореактора (Фиг. 5) с активна утайка и с смес от утайка (70%) и млечна суроватка (30%) с ХПК =  $10.2\text{ gO/L}$ . Като пример в Табл. 8 са показани някои резултати, отнасящи се до продукцията на биогаз ( $Q_1$  и  $Q_2$ ) и

пречистващия ефект в установено състояние за анаеробно разграждане на смес от утайка и млечна суроватка за две стойности на скоростта на разреждане ( $D_1$  и  $D_2$ ).

От експерименталните данни може да се направи извод, че за каскада от два биореактора общия дебит на продукцията на биогаз е с 25% по-висок и пречистващия ефект е около три пъти по-добър, отколкото в единичен биореактор.



Фиг. 5. Принципна схема на каскада от два анаеробни биореактора

### 2.3. Заключение

За целите на дисертационния труд в Институтът по микробиология „Ст. Ангелов” – БАН са проведени редица планирани експерименти и е натрупано голямо количество експериментални данни за трите основни типа БТП, предмет на изследванията в дисертационния труд – периодичен, полупериодичен и непрекъснат.

Проведени са експерименти с фунгалния щам *H. lutea* 103, продуцент на Cu/Zn – съдържаща СОД, при периодично култивиране и при полупериодично култивиране с подхранване с глюкоза в различни концентрации.

Проведени са експерименти при непрекъснатото АРОО с различни органични отпадъци в единичен биореактор и в каскада от два взаимосвързани биореактора. Експериментите са при различни скорости на разреждане и при прилагане на подходящи входни въздействия – стълаповидни и импулсни с глюкоза и ацетат.

И двата процеса, разглеждани в дисертационния труд, са от изключителна важност отчитайки физиологичната роля на ензима СОД и екологичния и енергетичен аспект на анаеробното разграждане.

Наличието на достатъчно на брой представителни експериментални данни за разглежданите процеси са добра основа за създаване на адекватни математически модели, както и за изследване възможностите на мощния апарат на ИНМ за моделиране на БТП.

## Глава 3. Детерминистични модели и наблюдатели на БТП

### 3.1. Детерминистично моделиране на периодичен процес за получаване на ензим СОД

На основата на изучаване на микробиологията на процеса, лабораторни експериментални данни и анализи за динамиката е разработен математически модел на периодичен процес за получаване на вътреклетъчния ензим СОД при използване на

щам *H. lutea* 103 и глюкоза като лимитиращ субстрат. Използвани са експериментални данни за средни стойности от четирикратно повтарящи се експерименти. Моделът е разработен с цел оптимизация и управление на разглеждания БТП. Симулационните изследвания и нелинейното оценяване са изпълнени на персонален компютър с използване на SIMULINK на MATLAB 6.5 и неговите пакети Optimisation и Signal Processing.

От анализа на експерименталните резултати се вижда, че едновременно с растежа и биосинтеза протичат явленията автолизис на биомаса и деградация на ензима. Поради това моделът, описващ растежа на биомасата, консумацията на глюкоза и формирането на ензима СОД при периодично култивиране, ще има следния общ вид:

$$\frac{dX}{dt} = \mu X = (\mu_c - \mu_1)X \quad (40)$$

$$\frac{dS}{dt} = -\rho X \quad (41)$$

$$\frac{dP}{dt} = \xi X = \varepsilon_S X - r_d \quad (42)$$

където  $S$ ,  $X$  и  $P$  са непрекъснати и диференцируеми, съответно  $X$  – концентрация на биомаса [g/L];  $S$  – концентрация на глюкоза [g/L];  $P$  – активност на ензима СОД [U/mg protein];  $\mu_c$  – специфична скорост на растеж;  $\mu_1$  – специфична скорост на автолизис;  $\rho$  – специфична скорост на консумация на глюкоза;  $\varepsilon_S$  – специфична скорост на биосинтеза на ензима СОД;  $r_d$  – скорост на деградация на ензима.

При формулирането и детайлизирането на модела са взети в предвид следните съображения:

1. Специфичната скорост на растеж на биомаса  $\mu_c$  обикновено зависи от концентрацията на лимитиращия субстрат (глюкоза) и/или концентрацията на биомаса:  $\mu_c = \mu_c(X, S)$ .

2. Специфичната скорост на автолизиса на биомаса  $\mu_1$  обикновено зависи от концентрацията на биомаса:  $\mu_1 = \mu_1(X)$ .

От анализа на функциите  $\mu = \mu(X)$  и  $\mu = \mu(S)$  и симулационни експерименти се достига до следната най-проста апроксимация на специфичната скорост на изменение на биомасата:  $\mu = k_1 S - k_2$ .

3. Специфичната скорост на биосинтеза на ензима обикновено зависи от специфична скорост на растежа на биомаса  $\mu_c$  и от концентрацията на лимитиращия субстрат  $S$ :  $\varepsilon_S = \varepsilon_S[S, \mu_c(X, S)]$ .

4. В случая се приема, че скоростта на деградация на ензима  $r_d$  е пропорционална на концентрацията на биомаса:  $r_d = kX$ .

Тази проста апроксимация на скоростта на деградация на ензима в случая е допустима, защото целта е разработването на модел, който да послужи за оптимално управление на процеса. От анализа на функциите  $\xi = \xi(X)$  и  $\xi = \xi(S)$  и симулационни експерименти се достига до следната най-проста полиномиална апроксимация на специфичната скорост на биосинтеза на ензима СОД:  $\xi = k_5 SX - k_6 - k_7 X$ .

5. Специфичната скорост на консумация на лимитиращ субстрат  $\rho$  е свързана с увеличението на количеството на биомасата, с формирането на продукта и с поддържането на жизнеспособността на микроорганизмите. Отчитайки горните

разсъждения и с някои опростявания на основата на симулационни експерименти, е възприет следният израз за  $\rho(S)$ :  $\rho = k_3 + k_4 S^2$ .

Горните разсъждения доведоха до следната система от три обикновени нелинейни диференциални уравнения, описваща кинетиката на периодичен биотехнологичен процес за получаване на вътреклетъчния ензим СОД:

$$\frac{dX}{dt} = k_1 SX - k_2 X \quad (49)$$

$$\frac{dS}{dt} = -k_3 X - k_4 S^2 X \quad (50)$$

$$\frac{dP}{dt} = k_5 SX^2 - k_6 X - k_7 X^2 \quad (51)$$


Задачата за оценяване на коефициентите на модела се свежда до нелинейно оценяване на седем неизвестни коефициенти при наличие на сравнително ограничен набор от силно зашумени експериментални данни за трите основни променливи:  $X$ ,  $S$  и  $P$ . Тя е решена в следните четири стъпки: 1) обработка на експерименталните данни; 2) декомпозиция на модела на две части; 3) оценяване на първата група от коефициентите; 4) оценяване на втората група от коефициентите.

Обработката на експерименталните данни се състои в увеличение на техния брой с помощта на кубичен сплайн и изглаждането им с филтър на Butterworth. Декомпозицията на модела се състои в разделянето му на две части с оглед опростяване и подобряване на процедурата на нелинейното оценяване. Първата част включва уравнения (49) и (50), които са зависими от променливите  $X$  и  $S$ , но не и от  $P$ . Втората част включва уравнение (51), зависимо и от  $P$ . Първо са оценени коефициентите  $k_1$ ,  $k_2$ ,  $k_3$  и  $k_4$  (от първата част на модела), а след това –  $k_5$ ,  $k_6$  и  $k_7$  (от втората част на модела). И в двата случая е използвана методика с оптимизационен метод при критерий минимизацията на сбора от най-малките квадрати между експерименталните и симулационните данни. Стойностите на получените коефициенти в модела (49) - (51) са представени в Табл. 9.

На Фиг. 6 са показани симулационните резултати, реалните експериментални данни и обработените експериментални данни за концентрациите на глюкоза ( $S$ ). На Фиг. 7 са показани симулационните резултати, реалните експериментални данни и обработените експерименталните данни за концентрациите на биомасата ( $X$ ), а на Фиг. 8 – за концентрация на ензима ( $P$ ).


Таблица 9

| Коефициент | Стойност  |
|------------|-----------|
| $k_1$      | 0.003692  |
| $k_2$      | 0.0008579 |
| $k_3$      | 0.001865  |
| $k_4$      | 0.0007156 |
| $k_5$      | 0.001     |
| $k_6$      | 0.00834   |
| $k_7$      | 0.001216  |




Фиг. 6. Субстрат

(\* експериментални данни; — обработени данни; --- симулационни данни)



Фиг. 7. Биомаса

(\* експериментални данни; — обработени данни; --- симулационни данни)



Фиг. 8. Продукт

(\* експериментални данни; — обработени данни; --- симулационни данни)

Получените резултати показват, че на базата на лабораторни експерименти и знания за процеса за получаване на СОД е разработен адекватен математически модел на периодичния процес. Много трудно е обаче да се избере подходяща нелинейна структура на математически модел с включване на разтворен кислород. В този случай може да бъде много полезен подходът на ИНМ.

### 3.2. Алгебрични наблюдатели на непрекъснат процес за анаеробно разграждане на органични отпадъци

Алгебричните наблюдатели са разработени на база тристъпалния модел, включващ хидролиза, ацидогенеза и метаногенеза. Този модел е разумен компромис между сложност и реалистичност на описанието на процесите на АРОО.

Предполага се, че всички параметри на модела са известни и оценката на специфичните скорости се прави въз основа на данни за измеримите динамични променливи, по-точно  $D$ ,  $Q$  и  $S_2$ .

$$\left\{ \begin{array}{l} \dot{S}_0 + DS_0 + \beta X_1 S_0 - DY_p S_{in} = 0 \\ \dot{X}_1 - \mu_1 X_1 + K_1 X_1 + DX_1 = 0 \\ Y_1 \dot{S}_1 + DY_1 S_1 - \beta X_1 Y_1 S_0 + \mu_1 X_1 = 0 \\ \dot{X}_2 - \mu_2 X_2 + K_2 X_2 + DX_2 = 0 \\ Y_2 \dot{S}_2 + DY_2 S_2 - Y_b \mu_1 Y_2 X_1 + \mu_2 X_2 = 0 \\ Q - Y_g \mu_2 X_2 = 0 \\ \dot{\beta} = 0 \\ \dot{k}_1 = 0 \\ \dot{k}_2 = 0 \\ \dot{Y}_1 = 0 \\ \dot{Y}_2 = 0 \\ \dot{Y}_b = 0 \\ \dot{Y}_g = 0 \\ \dot{Y}_p = 0 \end{array} \right. \quad (58)$$

Изводът за наблюдаемостта на специфичните скорости  $\mu_1$  и  $\mu_2$  при известни  $D$ ,  $Q$  и  $S_2$  е направен за следното характеристично множество от диференциални уравнения на системата (58) по отношение на следното старшинство:

$$\{D, Q, S_{in}, \beta, k_1, k_2, Y_1, Y_2, Y_b, Y_g, Y_p, S_2\}, \{\mu_1, \mu_2\}, \{X_1, X_2, S_0, S_1\} \quad (59)$$

Използвайки специализиран софтуер (*astb*), се получават следните три диференциални уравнения:

$$\begin{aligned} & -k_1 Y_2 Y_g \dot{S}_2 \mu_1 - k_1 Y_2 Y_g D S_2 \mu_1 + Y_2 Y_g \dot{S}_2 \dot{\mu}_1 + Y_2 Y_g D S_2 \dot{\mu}_1 + Y_2 Y_g \dot{S}_2 \mu_1^2 + \\ & + Y_2 Y_g S_2 D \mu_1^2 - Y_2 Y_g \ddot{S}_2 \mu_1 - 2 Y_2 Y_g D \dot{S}_2 \mu_1 - Y_2 Y_g \dot{D} S_2 \mu_1 - Y_2 Y_g D^2 S_2 \mu_1 - \end{aligned} \quad (60)$$

$$-k_1 Q \mu_1 + Q \dot{\mu}_1 + Q \mu_1^2 - \dot{Q} \mu_1 - D Q \mu_1 = 0$$

$$-k_2 D \mu_2 + Q \dot{\mu}_2 + Q \mu_2^2 - \dot{Q} \mu_2 - D Q \mu_2 = 0 \quad (61)$$

$$(Y_2 Y_b Y_g \mu_1) X_1 = Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2 \quad (62)$$

Уравнения (60) - (62) показват, че специфичните скорости  $\mu_1$  и  $\mu_2$  не са наблюдаеми по отношение на старшинството, дадено в (59), тъй като диференциалните уравнения, които ги представят, са от *I ред* по отношение на  $\mu_1$  и  $\mu_2$ . Затова се използват някои други диференциално-алгебрични подходи.

След алгебрични манипулации се получава следната оценяваща схема за  $\mu_2$ :

$$\begin{cases} \dot{z}_2 = -(D + k_2) z_2 + Q \\ \hat{\mu}_2 = \frac{Q}{z_2} \end{cases} \quad (63)$$

Изследването на уравнение (60) показва, че то може да бъде пренаписано както следва:

$$\begin{aligned} & \left( \frac{Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2}{\mu_1} \right)^{\bullet} = \\ & - (D + k_1) \left( \frac{Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2}{\mu_1} \right) + Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2 \end{aligned} \quad (64)$$

което дава следната оценяваща схема за  $\mu_1$ :

$$\begin{cases} \dot{z}_1 = -(D + k_1) z_1 + Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2 \\ \hat{\mu}_1 = \frac{Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2}{z_1} \end{cases} \quad (65)$$


С цел да се осъществи тази оценяваща схема, е нужно да се оцени  $\dot{S}_2$ . Това е направено, използвайки числено диференциране.

На основата на получените оценки на  $\mu_1$  и  $\mu_2$ ,  $X_1$  и  $X_2$  могат да бъдат оценени от уравнение (62) за  $X_1$  и чрез уравнението за дебита на биогаз в системата:


$$\hat{X}_1 = \frac{Q + Y_2 Y_g D S_2 + Y_2 Y_g \dot{S}_2}{Y_2 Y_b Y_g \hat{\mu}_1} = \frac{z_1}{Y_2 Y_b Y_g} \quad (66)$$

$$\hat{X}_2 = \frac{Q}{Y_g \hat{\mu}_2} = \frac{z_2}{Y_g} \quad (67)$$


За илюстрация на получените резултати са направени симулационни изследвания с модела на процеса. На Фиг. 9 е показана скоростта на разреждане, на Фиг. 10 – дебита на биогаз. На Фиг. 11 до Фиг. 14 са показани съответно оценките на специфичните скорости  $\mu_1$  и  $\mu_2$  и оценките на концентрациите на биомаси  $X_1$  и  $X_2$ .




Фиг. 9. Скорост на разреждане




Фиг. 10. Дебит на биогаз




Фиг. 11. Специфична скорост  $\mu_1$   
(— генерирани данни, — оценка)



Фиг. 12. Специфична скорост  $\mu_2$   
(— генерирани данни, — оценка)



Фиг. 13. Концентрация на биомаса  $X_1$   
(— генерирани данни, — оценка)



Фиг. 14. Концентрация на биомаса  $X_2$   
(— генерирани данни, — оценка)

### 3.3. Изводи

Проведените анализи и изследвания дават основание да се формулират следните основни изводи:

1. Математическото моделиране на процеса на периодично култивиране на вътреклетъчния ензим СОД е извършено на базата на сметите *off-line* експериментални данни за биомаса, лимитиращ субстрат (глюкоза) и ензим.
2. Разработен е детерминистичен модел на периодичен процес за получаване на ензима СОД при използване на щам *H. lutea 103* и глюкоза като лимитиращ субстрат. Моделът е от „познавателен тип”.

3. На базата на диференциално – алгебричния подход е изследвана наблюдаемостта на някои от основните неизмерими променливи в тристъпален модел на анаеробното разграждане на органични отпадъци.
4. Разработени са нови наблюдатели на специфичните скорости на растеж  $\mu_i$  и концентрациите на биомаса  $X_i$  ( $i = 1, 2$ ) при използването на тристъпален модел на АРОО.

## **Глава 4. Моделиране с апарата на изкуствените невронни мрежи на БТП**

За разработването на модели с апарата на ИНМ (за краткост наричани невронни модели) са използвани два специализирани софтуерни пакета: Neural network toolbox на MATLAB 6.5 и NNSYSID20, където е минимизиран критерий за най-малка средноквадратична грешка.

Доказано е, че ИНМ с един междинен слой могат достатъчно добре да апроксимират нелинейни функции от вида на разглежданите модели. Затова в настоящата работа невронните мрежи са двуслойни, като междинния слой е с 6 неврона в повечето случаи (броят им е определен експериментално), с активационни функции хиперболичен тангенс за междинния слой и линейна за изходния слой.

Валидация на получените модели е проведена по 2 начина: а) тестване на моделите с набор данни, невключени в обучението на модела; б) анализ на някои статистически характеристики. Корелационният анализ е често използван в идентификацията, като най-често изследвани са автокорелационната функция на грешките от предсказване на модела и взаимнокорелационните функции между входовете и грешките от предсказване.

Проведено е автоматично софтуерно „окастрияне“ (pruning) само на невронните модели с един вход и един изход, поради ограничения в използвания софтуерен пакет NNSYSID20.

### **4.1. Периодичен процес за получаване на ензим СОД**

За сравнение на детерминистичния и невронния подход при моделирането на БТП е разработен модел с апарата на изкуствените невронни мрежи на периодичен процес за получаване на ензима СОД. Входни данни за невронната мрежа са концентрациите на биомаса, субстрат и продукт и времето, а изходни данни – същите концентрации в следващия момент от времето.


Симулационните изследвания са изпълнени на персонален компютър с използване на пакета Neural Networks на MATLAB 6.5. За обучението на мрежата е избран алгоритъм за обратно разпространение на грешката.

Първоначално, за изследване възможностите на апарата на ИНМ за моделиране на процеса за получаване на СОД, са направени изследвания с данни, генерирани от разработения детерминистичен модел. Изследвани са невронни мрежи с различна топология (брой междинни слоеве), с различен брой неврони в тях и различни функции на изхода на невроните. Изпробвани са 6 различни структури на трислойни невронни мрежи (с два междинни слоя), с вариации в броя на невроните и праговите функции в двата междинни слоя. При всяка от тях след обучение при 1000 итерации се получава


разпознаване с много малка грешка при тестване с непознати данни. Затова са изследвани мрежи с по-проста структура с един междинен слой, като е разгледана работата на мрежи с 8 различни структури с вариации в броя на невроните и праговата функция в междинния слой. Всички тези мрежи при тестване след обучение при 1000 итерации разпознават с много малка грешка нови данни.

Всички мрежи са изследвани с експерименти по 264 обучаващи на входно-изходни двойки, при което се получават сравними резултати. Те са получени от модела при различна стъпка на дискретизация. В реалната практика се разполага с много по-малко на брой данни. Това налага да се изследва поведението на мрежата при намаляване на броя на данните от експериментите. За да се получат задоволителни резултати, трябва да се увеличи броя на невроните в междинния слой или да се смени функцията на изхода на невроните на междинния слой.

Изследвано е изменение на грешката при невронни мрежи с брой неврони в междинния слой от 7 до 20. Броят на итерациите е 1000. От всички локални минимума най-малки са съответно при 9 и 18 неврона. За 9 неврона – 0.0089, за 18 неврона – 0.0066. При 18 неврона времето за обучение се увеличава двойно. На Фиг. 15 е дадена графика на зависимостта на грешката от броя неврони в средния слой.



Фиг. 15. Зависимост на грешката от броя неврони




Фиг. 16. Зависимост на грешката от броя итерации


Изследвана е невронна мрежа с 9 неврона в междинния слой, обучавана при брой итерации от 100 до 2200. Най-малка грешка се получава при 1000 итерации – 0.0089 и при 2000 итерации – 0.0068. При 2000 итерации времето за обучение се увеличава двойно. На Фиг. 16 е дадена графика на зависимостта на грешката от броя итерации.

В резултат на горните изследвания за моделиране на изучавания биотехнологичен процес е избрана невронна мрежа с 9 неврона в междинния слой и функция хиперболичен тангенс на изхода на невроните на входния слой. Избраната невронна мрежа е обучена с данни, получени от модела (49) - (51) с 11 обучаващи двойки. Тестването е проведено с реални експериментални данни, обработени с филтър на Butterworth. Много по-добри резултати са получени, когато се увеличи броя на дискретните стойности в експериментите за обучение. На Фиг. 24 и 25 са дадени графики на реални данни, невронна мрежата и детерминистичен модел. Резултатите, показани на Фиг. 24 са след обучение на мрежата с 264 двойки, а на Фиг. 25 след обучение на мрежата с 22 двойки.

В резултат на проведените изследвания на невронни мрежи с различни структури и различен брой обучаващи данни е разработен невронен модел на периодичния процес за получаване на СОД. В Табл. 17 са представени стойностите на относителната средно-квадратична грешка ( $\varepsilon_{RMSE}$ ) за различните модели на процеса за получаване на СОД. Грешката показва, че невронният модел прогнозира по-добре от детерминистичния, а също така е по-лесен за проектиране. Това е по-силно изразено, когато броят на входно-изходните двойки за обучение е по-голям.




Фиг. 24. Модели и експериментални данни, 264 обуч. двойки (+ експ. данни за  $S$ ; — дет. модел на  $S$ ; - - - невр. модел на  $S$ ;  $\circ$  експ. данни за  $X$ ; — дет. модел на  $X$ ; - - - невр. модел на  $X$ ; \* експ. данни за  $P$ ; — дет. модел на  $P$ ; - - - невр. модел на  $P$ )




Фиг. 25. Модели и експериментални данни, 22 обуч. двойки (+ експ. данни за  $S$ ; — дет. модел на  $S$ ; - - - невр. модел на  $S$ ;  $\circ$  експ. данни за  $X$ ; — дет. модел на  $X$ ; - - - невр. модел на  $X$ ; \* експ. данни за  $P$ ; — дет. модел на  $P$ ; - - - невр. модел на  $P$ )

#### 4.1.1. С включване на разтворен кислород (без регулиране)

Възможностите на апарата на ИНМ позволяват включване на разтворен кислород в модела. Невронните модели са разработени на базата на седем последователни експеримента (три в 12-L и четири в 3-L биореактор). Шест експеримента са използвани за обучение и един за тестване на моделите. При моделирането са изследвани невронни мрежи с различни структури и най-добри резултати са получени при използването на невронна мрежа с един междинен слой с шест неврона и ARX-структура (авторегресионен с външни входове), т.е. моделът е *рекурентен*. Активационните функции са – хиперболичен тангенс за междинния и линейна за изходящия слой. Структурата на входящия слой се състои от една минала стойност на входа и две минали стойности на изхода. Входните данни за разтворен кислород са представени на Фиг. 26, а за глюкоза – на Фиг. 27. Проведени са 500 обучаващи итерации. Във всички изследвани случаи грешките при тестване са съизмерими с тези от обучението, което е доказателство за адекватност на моделите. „Окастриането“ (pruning) в общия случай не подобрява моделите. Корелационните характеристики за обучение и тестване са практически вътре в доверителните 95% интервали.



Фиг. 26. Входи (разтворен кислород) за периодичен процес с включване на разтворен кислород (без регулиране)



Фиг. 27. Входи (глюкоза) за периодичен процес с включване на разтворен кислород (без регулиране)

Разработени са невронни модели със следните структури:

- *SISO* – вход концентрацията на разтворен кислород, изход концентрацията на белтъци;
- *SISO* – вход концентрацията на разтворен кислород и предсказване концентрацията на биомаса;
- *SISO* – вход концентрацията на разтворен кислород, изход на специфичната активност на СОД;
- *MIMO* – входове концентрацията на разтворен кислород и концентрацията на глюкоза, изходи концентрацията на биомаса и специфичната активност на СОД.

Всички те при верификация с данни, неизползвани в обучението, дават много добри резултати с грешки, съизмерими с тези от обучението, в интервал  $-0.25 \div 0.25$ . Експерименталните и прогнозираните от моделите данни са представени на Фиг. 28.


#### 4.1.2. С включване на разтворен кислород (с регулиране)

Невронните модели са разработени на базата на експерименти, при които се регулира аерацията в системата, така че да се поддържат стъпаловидни входни въздействия от 20, 35, 50 и 60% кислородно насищане в биореактора. Проведени са общо седем експеримента – по два за кислородни нива 20, 35 и 50% и един при 60% кислород. Шест от тези експерименти са използвани за обучение и един за тестване на моделите.


При моделирането най-добри резултати са получени при топология на мрежата един междинен слой с шест неврона и рекурентен невронен модел с ARX-структура. Регресионната структура на входящия слой се състои от две предходни стойности на входа и три предходни стойности на изхода. Проведени са 500 обучаващи итерации. Във всички изследвани случаи грешките при тестване са съизмерими с тези от обучението. „Окастрияето“ не подобрява моделите. Двете изследвани корелационни характеристики при обучение, както и автокорелационната функция при тестване са вътре в доверителните интервали, но взаимнокорелационните функции при тестване са извън доверителните интервали.

Разработени са невронни модели със следните структури:

- *SISO* – вход концентрацията на разтворен кислород, изход концентрацията на белтъци;
- *SISO* – вход концентрацията на разтворен кислород, изход концентрацията на биомаса;
- *SISO* – вход концентрацията на разтворен кислород, изход специфичната активност на СОД.



Фиг. 28. Изходи за периодичен процес с включване на разтворен кислород (без регулиране)



Фиг. 30. Изходи за периодичен процес с включване на разтворен кислород (с регулиране)

Всички те при верификация с данни, неизползвани в обучението, дават много добри резултати с грешки, съизмерими с тези от обучението, в интервал  $-0.25 \div 0.25$ . Експерименталните и прогнозираните от моделите данни са представени на Фиг. 30.

Многомерните модели в този случай не дадоха добри резултати.

## **4.2. Полупериодичен процес за получаване на ензим СОД с включване на глюкоза като лимитиращ субстрат**

### **4.2.1. Обработка на експерименталните данни**

Реалните експериментални данни са неподходящи за моделиране на процесите, тъй като са зашумени. За да могат да бъдат разработени невронните модели, експерименталните данни се изглаждат с филтър на Butterworth от 2-ри и 4-ти ред. За обучение на невронните мрежи е нужно данните да бъдат равномерно разпределени във времето. Когато това не е изпълнено данните се обработват и с кубичен сплайн. Кубичен сплайн се използва също и за размножаване на данните, тъй като в някои от случаите те са недостатъчни за обучение на моделите. Експерименталните данни, както и обработените експериментални данни за концентрациите на субстрат и биомаса и активност на ензима СОД са показани съответно на Фиг. 34 - 36.

### **4.2.2. Невронно моделиране**

Невронните модели са разработени на базата на пет последователни експеримента. Четири от тях са полупериодични, с добавяне на глюкоза в концентрации 0.75, 1.0, 1.5 и 2.0 g/L съответно (Фиг. 37) и един периодичен процес (базов) без добавяне на глюкоза. Три полупериодични експеримента (0.75, 1.5 и 2.0 g/L) са използвани за обучение и един (1.0 g/L) за тестване на моделите. Най-добри резултати са получени с мрежа с шест неврона в междинния слой при 100 обучаващи итерации. Във всички изследвани случаи грешките при тестване са съизмерими с тези от обучението. „Окастриането“ не подобрява моделите. Корелационните характеристики за обучение и тестване са практически вътре в доверителните 95% интервали, с изключение на характеристиките при тестване на модела с вход концентрацията на глюкоза и изход концентрацията на белтъци.

Разработени са невронни модели със следните структури:

- *SISO* – вход концентрацията на глюкоза, изход концентрацията на белтъци;
- *SISO* – вход концентрацията на глюкоза, изход концентрацията на биомаса;
- *SISO* – вход концентрацията на глюкоза, изход тоталната активност на СОД.

Всички те при верификация с данни, неизползвани в обучението, дават добри резултати с грешки, съизмерими с тези от обучението, в интервал  $-0.25 \div 0.2$ .


Многомерните модели в този случай не дадоха добри резултати.

В досегашните ни изследвания не бе достигнато до добър детерминистичен модел на полупериодичния процес на получаване на ензима СОД, въпреки обнадеждаващите начални резултати. Такъв не ни е известен и от литературните проучвания.


Разработените модели с апарата на ИНМ се оказаха неуспешни по отношение на определянето на оптималното подхранване с глюкоза. Те биха могли да се използват само за прогнозиране на поведението на някои неизмерими променливи т.е. да се използват като “софтуерни сензори”. Напр. прогнозиране на изменението на СОД при

две различни концентрации на подхранващата глюкоза е представено на Фиг. 41 (при подхранване с глюкоза 1.5 g/L) и Фиг. 42 (при подхранване с глюкоза 2 g/L).


Оказа се, че е много по-удачно да се използва хибридният подход, при който само специфичните скорости  $\mu$ ,  $\rho$  и  $\xi$  в едностъпалния детерминистичен модел на процеса се моделират като ИНМ.




Фиг. 34. Концентрация на глюкоза при полупериодичен процес




Фиг. 35. Концентрация на биомаса при полупериодичен процес




Фиг. 36. Концентрация на ензим при полупериодичен процес



Фиг. 37. Входи за полупериодичен процес



Фиг. 41. Сравнение на резултатите от софтуерен сензор — с експериментални данни —



Фиг. 42. Сравнение на резултатите от софтуерен сензор — с експериментални данни —

#### 4.2.3. Хибридно моделиране

Разглежда се следния опростен модел на полупериодичен биотехнологичен процес:

$$\frac{dX}{dt} = \mu X \quad (74)$$

$$\frac{dS}{dt} = -\rho X + \frac{F}{V} S_{in} \quad (75)$$

$$\frac{dP}{dt} = \xi X - kP \quad (76)$$

### Хибриден модел, в който $\mu$ се оценява с невронна мрежа

Разработен е хибриден модел, при който в модела (74) - (76) специфичната скорост на растеж на микроорганизмите  $\mu$  се оценява с невронна мрежа, а другите две специфични скорости са детерминистични функции. Изследвани са различни структури невронни мрежи, при които входове на невронната мрежа са:

- $S$ ;
- $S$  и  $\mu$  – рекурентна невронна мрежа;
- $S$  и  $X$ ;
- $S$ ,  $X$  и  $\mu$  – рекурентна невронна мрежа.

Най-добри резултати са получени когато входове за невронната мрежа са  $S$ ,  $X$  и  $\mu$ .

### Хибриден модел, в който $\mu$ и $\rho$ се оценяват с невронни мрежи

Разработен е хибриден модел, при който специфичната скорост на растеж на микроорганизмите  $\mu$  и специфична скорост на потребление на лимитиращия субстрат  $\rho$  се оценяват с невронни мрежи, а  $\zeta$  е детерминистична функция. За  $\mu$  е използвана невронна мрежа с определената по-горе структура. За  $\rho$  са изследвани различни структури невронни мрежи с входове:

- $S$  и  $X$ ;
- $S$ ,  $X$  и  $\rho$  – рекурентна невронна мрежа.

По-добри резултати са получени когато входове за невронната мрежа са  $S$  и  $X$ .

### Хибриден модел, в който $\mu$ , $\rho$ и $\zeta$ се оценяват с невронни мрежи

Разработен е хибриден модел, при който специфичната скорост на растеж на микроорганизмите  $\mu$ , специфична скорост на потребление на лимитиращия субстрат  $\rho$  и специфична скорост на образуване на целеви продукт  $\zeta$  се оценяват с невронни мрежи. За  $\mu$  и  $\rho$  са използвани невронни мрежи с определените по-горе структури. За  $\zeta$  са изследвани различни структури невронни мрежи като най-добри резултати са получени при входове на невронната мрежа  $S$ ,  $X$  и тотална активност на изследвания ензим СОД. Сравнение на резултатите от хибридният модел с експерименталните данни е показано на Фиг. 43.

Таблица 17

| Прогнозирана величина                                                                                                     | Глюкоза | Биомаса | Белтък | Ензим СОД |
|---------------------------------------------------------------------------------------------------------------------------|---------|---------|--------|-----------|
| $\varepsilon_{RMSE}$ на детерминистичен модел за периодично получаване на СОД                                             | 0.7826  | 0.1038  | -      | 0.1846    |
| $\varepsilon_{RMSE}$ на невронен модел за периодично получаване на СОД                                                    | 0.0007  | 0.0016  | -      | 0.0010    |
| $\varepsilon_{RMSE}$ на невронен модел за периодично получаване на СОД с включване на разтворен кислород (без регулиране) | -       | 0.0002  | 0.0029 | 0.0155    |
| $\varepsilon_{RMSE}$ на невронен модел за периодично получаване на СОД с включване на разтворен кислород (с регулиране)   | -       | 0.0058  | 0.0089 | 0.0056    |
| $\varepsilon_{RMSE}$ на хибриден модел за полупериодично получаване на СОД                                                | 0.0017  | 0.0714  | -      | 0.0131    |

При верификация, разработеният хибриден модел на полупериодичен процес за получаване на ензима СОД, при който специфичните скорости (на растеж на биомаса, консумация на субстрат и формиране на ензим) са моделирани с апарата на ИНМ показва висока степен на точност. В Табл. 17 са представени стойностите на относителната средно-квадратична грешка ( $\varepsilon_{RMSE}$ ) за различните модели на процеса за получаване на СОД. Грешката за хибридният модел е малка и показва, че той е подходящ за моделиране на процеса. Моделът е добра база за разработване на стратегия за оптимално управление на процеса.

### 4.3. Непрекъснат процес за анаеробно разграждане на органични отпадъци

Първоначално, с цел изследване възможностите на апарата на ИНМ за моделиране процеса на АРОО, са направени редица изследвания с генерирани от модел данни, включващ добавянето на глюкоза и ацетат за стимулиране на анаеробното разграждане, при отчитане и на хидролизния процес.

Като реални входове на невронните модели на разглеждания процес са приети  $D_1$ ,  $D_2$ ,  $S_{0i}$  (смущение),  $S_{10}''$ , а като изходи –  $Q$  и ХПК. Изследвани са два типа структури невронни мрежи:

#### Едномерни (SISO):

- Управляващото въздействие “скорост на разреждане за входящата органика” в биореактора ( $D_1$ ) е прието за вход, а за изход – добива на биогаз ( $Q$ );
- Управляващото въздействие “скорост на разреждане за входящата органика” в биореактора ( $D_1$ ) е прието за вход, а за изход – ХПК;
- Управляващото въздействие “концентрация на подаваната глюкоза” в биореактора ( $S_{10}''$ ) е прието за вход, а за изход – добива на биогаз ( $Q$ );
- Управляващото въздействие “концентрация на подаваната глюкоза” в биореактора ( $S_{10}''$ ) е прието за вход, а за изход – ХПК;
- Неизмеримото смущение “концентрация на замърсяващата органика” на входа на биореактора ( $S_{0i}$ ) е прието за вход, а за изход – добива на биогаз ( $Q$ ).

#### Многомерни:

- MISO - два входа ( $S_{10}''$  и  $S_{0i}$ ) и един изход ( $Q$ );
- MIMO - два входа ( $S_{10}''$  и  $S_{0i}$ ) и два изхода ( $Q$  и ХПК).

При моделирането са изследвани невронни мрежи с различни структури и като най-подходяща е избрана структура с един междинен слой с шест неврона и активационни функции – хиперболичен тангенс за междинния и линейна за изходящия слой. При MIMO модела най-добри резултати са получени при 9 неврона в междинния слой. Резултатите от моделирането са представени в Табл. 18. При обучението и тестването на мрежите са използвани стъпални входни въздействия с различни амплитуди.


При многомерните случаи е изследвано също обучение на мрежата със стъпаловидно входно въздействие по  $S_{10}''$  и синусоидално входно въздействие по  $S_{0i}$ . най-добри резултати са получени при 8 неврона в междинния слой. Използвана е линейна регресия от 2 ред за всички променливи при синтезиране на входния вектор.

Резултатите от верификацията са добри, с грешки в интервала  $-0.02 - 0.03$  за изход  $Q$  и в интервала  $-0.1 - 0.3$  за изход ХПК, съизмерими с тази от обучението.


На Фиг. 72 са показани резултати от верификацията с реални експериментални данни на НМ с един вход и един изход, обучена с генерирани данни. Вижда се, че мрежата принципно реагира правилно, като по-големите различия в 4-ия и 15-ия дни могат да се обяснят с нулирането на  $D_1$  в условията на реалния експеримент в тези дни (което бе наложено от намаляващото рН в биореактора, неотразено в модела).

Таблица 18

| Модел                           | Входен вектор                                                                  | Брой итерации за обучение | Грешка при обучение                                           | Грешка от тестване                                            |
|---------------------------------|--------------------------------------------------------------------------------|---------------------------|---------------------------------------------------------------|---------------------------------------------------------------|
| $D_1 - Q$                       | $D(t-1), Q(t-1), Q(t-2)$                                                       | 300                       | -0.007 до 0.007                                               | -0.015 до 0.015                                               |
| $D_1 - \text{ХПК}$              | $D(t-1), \text{ХПК}(t-1), \text{ХПК}(t-2), \text{ХПК}(t-3), \text{ХПК}(t-4)$   | 300                       | -0.004 до 0.004                                               | -0.06 до 0.08                                                 |
| $S_{10}'' - Q$                  | $S_{10}''(t-1), Q(t-1), Q(t-2)$                                                | 49                        | -0.006 до 0.003                                               | -0.007 до 0.005                                               |
| $S_{10}'' - \text{ХПК}$         | $S_{10}''(t-1), \text{ХПК}(t-1), \text{ХПК}(t-2)$                              | 146                       | -0.07 до 0.07                                                 | -0.07 до 0.07                                                 |
| $S_{0i} - Q$                    | $S_{0i}(t-1), Q(t-1), Q(t-2)$                                                  | 63                        | -0.003 до 0.003                                               | -0.003 до 0.003                                               |
| $S_{10}''$ и $S_{0i} - Q$       | $S_{10}''(t-1), S_{0i}(t-1), Q(t-1), Q(t-2)$                                   | 109                       | -0.006 до 0.004                                               | -0.006 до 0.004                                               |
| $S_{10}''$ и $S_{0i} - Q$ и ХПК | $S_{10}''(t-1), S_{0i}(t-1), Q(t-1), Q(t-2), \text{ХПК}(t-1), \text{ХПК}(t-2)$ | 300                       | За изход $Q$<br>-0.015 до 0.01<br>За изход ХПК<br>-0.2 до 0.2 | За изход $Q$<br>-0.015 до 0.01<br>За изход ХПК<br>-0.2 до 0.2 |



Фиг. 43. Сравнение на резултатите от хибриден модел — с експериментални данни за  $S(\cdot)$ ,  $X(+)$  и  $\text{СОД}(*)$



Фиг. 72. Верификация с реални данни — реални данни, — невронна мрежа

#### 4.3.1. Модели с реални експериментални данни


На основата на получените знания от дотук представените изследвания бяха проведени и изследвания с реални експериментални данни снети с представената лабораторна биогазова инсталация на Института по микробиология „Ст. Ангелов”, БАН. Проведени са експериментални изследвания при органични отпадъци от животновъдството - говежди тор. Невронните модели в този случай бяха обучени и верифицирани изцяло с реални данни. За целите на моделирането и идентификацията са приложени подходящи стъпаловидни и импулсни входни въздействия към съответния управляващ вход.

### Вход $S_{10}''$ , изход $Q$


На Фиг. 73 са показани резултатите за невронния модел  $S_{10}'' - Q$  с реални изменения на входното въздействие както в аналогичния теоретичен случай, но при обучение с реални данни за  $Q$ , на Фиг. 74 – при тестване с реални данни за  $Q$ , а на Фиг. 75 – резултати от тестване с реално данни за  $Q$ , при входно въздействие импулс.

Вижда се, че реалните данни са доста близки с прогнозираните им стойности. Анализирайки обаче внимателно Фиг. 73 и Фиг. 74 може да се забележи, че невронният модел няма добри апроксимиращи свойства, за разлика от детерминистичния модел.


На Фиг. 76, 77 и 78 са показани АКФ (в горната част) и ВКФ (в долната им част) за трите случая. Те са практически вътре в доверителните интервали, от което може да се направи заключението, че по всички показатели моделът е добър.




Фиг. 73. Обучение с реални данни при стъпаловидно входно въздействие на невронен модел  $S_{10}'' - Q$   
(o – реалните данни, \* – прогнозни изходи на мрежата)




Фиг. 75. Тестване с реални данни при импулсно входно въздействие на невронен модел  $S_{10}'' - Q$   
(o – реалните данни, \* – прогнозни изходи на мрежата)




Фиг. 74. Тестване с реални данни при стъпаловидно входно въздействие на невронен модел  $S_{10}'' - Q$   
(o – реалните данни, \* – прогнозни изходи на мрежата)



Фиг. 76. Статистически характеристики при обучение с реални данни и стъпаловидно входно въздействие на невронен модел  $S_{10}'' - Q$



Фиг. 77. Статистически характеристики при тестване с реални данни и стъпаловидно входно въздействие на невронен модел  $S_{10}'' - Q$



Фиг. 78. Статистически характеристики при тестване с реални данни и импулсно входно въздействие на невронен модел  $S_{10}'' - Q$

### Вход $D_1$ , изход $Q$

Разработени са също така невронни модели на динамиката между подхранванията с отпадъци от животновъдството (говежди тор) и стимулираща субстанция (ацетат) като управляващи входове от една страна, и от друга – скоростта на получаване на биогаз като управляем изход, за непрекъснат процес на анаеробно разграждане.

$D_1$  е скорост на разреждане (управляващ вход) за добавяне на говежди тор с концентрация  $S_{0i}$  (в нашия случай  $S_{0i} = \text{const}$ ).  $S_{20}$  е концентрацията на добавен ацетат (управляващ вход) със скорост на разреждане  $D_2$  (в нашия случай  $D_2 = \text{const}$ ).  $D = D_1 + D_2$  е общата скорост на разреждане, а скоростта на получаване на биогаз  $Q$  е измеримия изход.

НМ са двуслойни, с един междинен слой с 6 неврона (броят им е определен експериментално) и активационни функции – хиперболичен тангенс за междинния и линейна за изходящия слой. Избрани са ИНМ с APX структура.


Реалните физически входове, които са приети за тези невронни модели на анаеробното разграждане са  $D_1$  и  $S_{20}$ , а изход е  $Q$ .

Направени са лабораторни експерименти със стъпаловидни изменения на входното въздействие  $D_1$ . Най-добри резултати при обучението и тестването са получени при използване на входни данни за мрежата за  $D_1(t-1)$  и  $Q(t-1)$ , изход  $Q(t)$ . Някои резултати от обучението на невронен модел  $D_1 - Q$  са показани на Фиг. 79, където реалните експериментални данни за реакцията на изхода ( $Q_{\text{exp}}$ ) при входното въздействие от Табл. 38 са представени с кръгчета, а предиктивния изход на невронния модел ( $Q_m$ ) за същото входно въздействие – с непрекъсната линия. Невронният модел е обучен за 500 итерации. Той притежава също толкова добри апроксимиращи свойства като съответния детерминистичен модел, но конструирането му е много по-лесно.

### Вход $S_{20}$ , изход $Q$


Направени са лабораторни експерименти със стъпаловидни и импулсни изменения на входното въздействие. Най-добри резултати при обучението и тестването са получени при използване на входни данни за мрежата за  $S_{20}(t-1)$  и  $Q(t-1)$ , изход  $Q(t)$ . Експерименталните данни за реакцията на изхода ( $Q_{\text{exp}}$ ) при входното въздействие от Табл. 39 са представени на Фиг. 80 със звездички. В този случай експерименталните данни са много зашумени, за това е невъзможно да се получи добър резултат без

предварителна обработка. За целите на моделирането тези данни са филтрирани с филтър на Butterworth от 2<sup>ри</sup> ред. Филтрираните данни  $Q_f$  (показани на Фиг. 80 с непрекъсната линия) са използвани за обучението на невронния модел  $S_{20} - Q$ . Моделът е обучен за 100 итерации.




Фиг. 79. Модел  $D_1 - Q$ : реакция на изхода  $Q$  за входно въздействие  $D_1$  от Табл. 38  
( $\circ - Q_{\text{exp}}$ , — —  $Q_m$ )

На Фиг. 81 са показани някои резултати от тестването на получения модел. Експерименталните данни за реакцията на изхода ( $Q_{\text{exp}}$ ) при импулсно входно въздействие с амплитуда 1.5 g/L са представени с кръгчета, а предиктивния изход на невронния модел ( $Q_m$ ) — с непрекъсната линия. Този невронен модел притежава добри апроксимиращи свойства и конструирането му е много по-лесно отколкото на детерминистичен нелинеен модел.



Фиг. 80. Модел  $S_{20} - Q$ : реакция на изхода  $Q$  за входно въздействие  $S_{20}$  от Табл. 39 (\* —  $Q_{\text{exp}}$ , — —  $Q_f$ )



Фиг. 81. Модел  $S_{20} - Q$ : реакция на изхода  $Q$  за импулсно входно въздействие  $S_{20}$  с амплитуда 1.5 g/L ( $\circ - Q_{\text{exp}}$ , — —  $Q_m$ )

Тестването на невронни модели с данни, различни от тези за обучение, представя адекватността (валидността) на моделите. Във втория изследван случай, средно квадратичните грешки ( $MSE$ ) са съизмерими при обучение и тестване. Това е важен показател за адекватността на получения модел. Получените стойности за  $MSE$  са показани в Табл. 40.

За невронния модел  $D_1 - Q$ , изходът на модел  $Q_m$  следва съответната траектория на реалните данни със стойност на  $MSE = 0.0029$ .

За невронния модел  $S_{20} - Q$ , изходът на модел  $Q_m$  следва съответната траектория на филтрираните данни със стойност на  $MSE = 4.54 \times 10^{-4}$ . За сравнение,  $MSE$  между реалните експериментални данни и изхода на невронния модел е 0.0058. При тестване,  $Q_m$  следва съответната траектория на реалните данни със стойност на  $MSE = 0.0053$ .

За целите на валидацията на моделите, са изследвани също така и статистическите характеристики АКФ и ВКФ. Стойностите на доверителните интервали са представени в Табл. 40. За двата изследвани случая с реални експериментални данни, АКФ и ВКФ при обучение и тестване практически са вътре в доверителните интервали. Следователно по този признак моделите също са адекватни.

Таблица 40

| Модел                     | Средно квадратична грешка |                       |          | Доверителни интервали |              |
|---------------------------|---------------------------|-----------------------|----------|-----------------------|--------------|
|                           | Обучение                  |                       | Тестване | Обучение              | Тестване     |
|                           | Реални данни              | Филтрирани данни      |          |                       |              |
| $D_1 - Q_{\text{exp}}$    | 0.0229                    | -                     | -        | $\pm 0.1706$          | -            |
| $S_{20} - Q_{\text{exp}}$ | 0.0058                    | $4.54 \times 10^{-4}$ | 0.0053   | $\pm 0.2011$          | $\pm 0.5436$ |

#### 4.3.2. Моделиране на каскада от два биореактора

Два взаимосвързани биореактора (каскада) показват някои предимства в сравнение с единичен биореактор с непрекъснато разбъркване, отнасящи се до деградацията на отпадъците и продукцията на биогаз.

Съществува нелинейна зависимост между основните променливи на процеса – концентрации на биомасата и субстрата на различните типове микроорганизми, скорост на разреждане и скорост на получаване на биогаз. Тези зависимости се изменят значително с промяната на характеристиките на входящата разтворима органика и това рефлектира върху съществуващите нестационарности и нелинейности на модела, променят се параметрите и техните взаимовръзки. Различни математически модели описват тези зависимости, но е необходимо да се премине през трудната процедура на параметрична идентификация при всяка промяна на входящата разтворима органика. Като опит да бъде разрешен този проблем е разработен опростен нелинеен модел с използване апарата на ИНМ, който може да прогнозира дебита на получавания биогаз (крайния продукт) в двата биореактора.


Целта на изследването е да се разработи невронен модел за каскада от два анаеробни биореактора (Фиг. 5), като се използват данни, генерирани от детерминистичен модел и експериментални данни, получени в лабораторни условия.

##### Невронен модел с генерирани данни

**Структура на модела.** Включвайки някои измерими променливи, описващи процеса, за двустъпалния невронен модел е възприета структурата, показана на Фиг. 83.  $D_1$  и  $D_2$  са скоростите на разреждане съответно за първият (БР<sub>1</sub>) и вторият (БР<sub>2</sub>) биореактори,  $S_0$  е концентрацията на разтворимата органика в БР<sub>1</sub>,  $S_{21}$  е концентрацията на ацетат в БР<sub>1</sub>,  $Q_1$  и  $Q_2$  са скоростите на потоците на биогаз в БР<sub>1</sub> и БР<sub>2</sub>.

Като първа задача на това проучване е изследвана способността на апарата на ИНМ за моделиране на процеса, използвайки планирани числови експерименти с данни, генерирани от детерминистичен модел. Данните за обучение и валидация

представяват различни стъпаловидни и импулсни поредици. За това изследване обема на БР<sub>1</sub> е:  $V_1 = 2$  L, обема на БР<sub>2</sub> е:  $V_2 = 14$  L, следователно  $N = \frac{V_2}{V_1} = 7$ .



Фиг. 83. Структура на невронния модел с генерирани данни

**Обучение.** Най-добри резултати са получени при използването на рекурентна невронна мрежа с ARX-структура. За ИНМ<sub>1</sub> входовете са:  $D_1(k)$ ,  $S_0(k)$ ,  $Q_1(k)$  и  $S_{21}(k)$ ; изходите са:  $Q_1(k+1)$  и  $S_{21}(k+1)$ , където  $k$  е цялото число в дефиницията на дискретното време  $kT$ . За ИНМ<sub>2</sub> входовете са:  $D_2(k)$ ,  $S_{21}(k)$  и  $Q_2(k)$ ; изходът е  $Q_2(k+1)$ . Фундаменталният Levenberg-Marquardt метод е използван като обучаващ алгоритъм. Топологиите на невронните мрежи са както следва: 2-6-2 за ИНМ<sub>1</sub> и 2-6-1 за ИНМ<sub>2</sub>. Първият вход на ИНМ<sub>2</sub> е пропорционален на първият вход на ИНМ<sub>1</sub> ( $D_2 = D_1/7$  защото вторият биореактор е 7 пъти по-голям от първият). Вторият вход на ИНМ<sub>2</sub> е равен на вторият изход на ИНМ<sub>1</sub> (виж Фиг. 83). Периодът на дискретизация за всички сигнали от този експеримент е  $T = 0.5$  ден. Скоростите на потоците биогаз  $Q_1$  и  $Q_2$  и субстратната концентрация  $S_{21}$  следват траекторията на съответния сигнал със стойности на  $MSE$  по-малки от  $3.2 \times 10^{-5}$  за 200 обучаващи итерации.

**Проверка за валидност.** При сравнение на невронния модел с нов набор данни, различен от обучаващия, се получават резултати подобни на тези от обучението. Скоростите на дебитите на биогаз  $Q_1$  и  $Q_2$  и субстратната концентрация  $S_{21}$  следват траекторията на съответния сигнал със стойности на  $MSE$  не по-големи от  $3.0 \times 10^{-5}$ .


### Невронен модел с реални данни

В случай на промяна на вида отпадък за процеса на анаеробно разграждане става много трудно да се намерят новите коефициенти на детерминистичния модел. Като алтернатива на тази сложна процедура за намиране на подходящи коефициенти, се предлага да се обучи нов невронен модел за активна утайка на базата на генерирани данни от детерминистичен модел, като се променят само два от неговите коефициенти ( $Y_{gl}$  и  $Y_{g2}$ ). Новите стойности на тези коефициенти ( $Y_{gl} = 15$ ;  $Y_{g2} = 85$ ) са получени чрез прости числови експерименти, изравнявайки статичните нива за скорост на получаване на биогаз в двата биореактора на експерименталните и моделни данни за три стойности на  $D$ .


**Обучение.** Поради недостатъчно експериментални данни за  $S_0$  и  $S_{21}$  е невъзможно да се обучи описаният по-горе невронен модел с реални експериментални данни за анаеробното разграждане на активна утайка. В този случай най-добри резултати са получени със следната ИНМ топология: 1-4-1, като входове са  $D_1$  и  $D_2$ ; изходи са  $Q_1$  и  $Q_2$  съответно за първата и втората ИНМ. Същата топология беше препоръчана от софтуерната система NeuCom, при която е приложен подходът DENFIS (Dynamic Evolving Neuro-Fuzzy Inference System). Това е метод, предлагащ определяне на оптималния брой неврони в междинния слой на невронната мрежа. За ИНМ<sub>1</sub> входовете са  $D_1(k)$  и  $Q_1(k)$ ; изходите са  $Q_1(k+1)$ . За ИНМ<sub>2</sub> входовете са  $D_2(k)$  и  $Q_2(k)$ ; изходите са

$Q_2(k+1)$ . Този модел бе обучен с данни, генерирани от детерминистичния модел при новите стойности на  $Y_{g1}$  и  $Y_{g2}$ . Периодът на дискретизация за всички сигнали е  $T = 1$  ден и е равен на този на реалния експеримент. Резултатите от обучението показват, че невронният модел следва траекторията на съответния сигнал със стойности на  $MSE$  по-малки от 0.11 за 100 обучаващи итерации.

**Проверка за валидност.** Валидацията на невронния модел е направена с реални експериментални данни. Резултатите са показани на Фиг. 95 за ИНМ<sub>1</sub> и на Фиг. 96 за ИНМ<sub>2</sub>, където входните въздействия  $D_1$  и  $D_2$  са представени с непрекъснати черни линии; реалните експериментални данни за изходите ( $Q_{1\text{exp}}$  и  $Q_{2\text{exp}}$ ) са представени със звезди; резултатите от детерминистичния модел са представени с пунктирни линии с точки ( $Q_{1\text{DM}}$  и  $Q_{2\text{DM}}$ ); прогнозираните от невронния модел изходи ( $Q_1$  и  $Q_2$ ) за същите входни въздействия – с непрекъснати линии. Стойностите на грешките за скоростите на получаване на биогаз, между моделите и реалните данни са дадени в Табл. 42. Вижда се, че невронния модел има по-добри прогнозиращи свойства.



Фиг. 95. Реални данни  $Q_{1\text{exp}}$ , изход на невронен модел  $Q_1$ , изход на детерминистичен модел  $Q_{1\text{DM}}$  и входно въздействие  $D_1$  за ИНМ<sub>1</sub>



Фиг. 96. Реални данни  $Q_{2\text{exp}}$ , изход на невронен модел  $Q_2$ , изход на детерминистичен модел  $Q_{2\text{DM}}$  и входно въздействие  $D_2$  за ИНМ<sub>2</sub>

Таблица 42

| Модел                   | Средно квадратична грешка |
|-------------------------|---------------------------|
| Детерминистичен модел 1 | 0.164                     |
| ИНМ <sub>1</sub>        | 0.123                     |
| Детерминистичен модел 2 | 0.062                     |
| ИНМ <sub>2</sub>        | 0.042                     |

#### 4.4. Изводи

На базата на получените резултати могат да се дефинират следните изводи:

1. Разработен е невронен модел на периодичен процес за получаване на ензима СОД без регулиране на разтворен кислород. Резултатите могат да бъдат използвани за прогнозиране с една стъпка напред във времето на неизмеримите в реално време променливи на състоянието (концентрация на белтъци, концентрация на биомаса и активност на ензима).
2. Разработен е невронен модел на периодичен процес за получаване на ензима СОД с включване на разтворения кислород като управляващ вход. Моделът е добра база за разработване на стратегия за оптимално управление на процеса.
3. Разработен е хибриден модел на полупериодичен процес за получаване на ензима СОД, при който специфичните скорости (на растеж на биомаса, консумация на субстрат и формиране на ензим) са моделирани с апарата на ИНМ. Моделът е добра база за разработване на стратегия за оптимално управление на процеса.
4. При периодичен и полупериодичен процес за получаване на СОД в някои случаи съществуват трудности при получаване на достатъчно на брой експериментални данни за обучение на невронните модели. За да се използва невронна мрежа за моделиране на изследвания процес е необходимо броят на експерименталните данни да е минимум 22.
5. Разработени са невронни модели на АРОО за единичен биореактор. Моделите могат да се използват за прогнозиране с една стъпка напред във времето на дебита на получавания биогаз за различни скорости на разреждане и за синтез на управление на процеса.
6. На базата на реални експериментални данни за анаеробно разграждане на говежди тор, са разработени сравнително прости входно-изходни невронни модели на този процес. Валидацията на моделите дава много добри резултати – практически без статична грешка и незначителна динамична грешка. Получените модели могат да бъдат използвани за прогнозиране добива на биогаз в биореактор, подхранван с говежди тор за различни скорости на разреждане.
7. Разработен е невронен модел на анаеробно разграждане на активна утайка в каскада от два анаеробни биореактора. Моделът може да бъде използван за прогнозиране с една стъпка напред във времето на дебита на получавания биогаз в двата биореактора за различни скорости на разреждане. Той показва по-добра динамика в сравнение със съответния детерминистичен модел и може да бъде използван за целите на управлението.
8. Получените резултати потвърждават възможностите на апарата на изкуствените невронни мрежи за моделиране на БТП. Предложеният апарат притежава някои предимства, сравнен с класическия детерминистичен подход за моделиране –

простота на моделите, бързина при синтезирането им, отсъствие на необходимост за идентифициране на физиологични и биохимични параметри.

9. Там, където моделирането с ИНМ не дава задоволителни резултати, е предложен вариант за хибридно моделиране. При него са използвани балансните уравнения от базовите детерминистични структури, като специфичните скорости са моделирани като невронни мрежи. С този подход се избягва идентификацията на специфичните скорости, които са носители на най-голямата нелинейност в моделите.
10. Получените резултати дават основание апарата на изкуствените невронни мрежи да се използва при моделирането на БТП.

## Глава 5. Оптимизация на БТП

Разглежда се моделът (74) - (76) за процесът на полупериодично култивиране на СОД. При определянето на оптималната последователност от управляващи въздействия  $[U_{max}, U_{min}, u_{sing}]$  може да се използват натрупаните микробиологични и биохимични знания за процеса.

От физически съображения  $u$  е ограничено:

$$0 \equiv U_{min} \leq u(t) \leq U_{max} \quad (120)$$

В реални условия  $x_0$  е известно, като  $V(0)$  се изчислява, а  $S(0)$  е фиксирано. Очевидно е, че оптималната последователност на управленията зависи от  $S(0)$ . Реалистично е също така да се допусне, че  $X(0)$  е малко.


**Случай 1:**  $S(0) \ll S_{кр}$

$S_{кр}$  – стойност, над която субстрата в биореактора е в инхибиращо количество.


Тъй като  $\mu$  е растящо с отчитане на  $S$ , в този случай в момента  $t = 0$  управлението трябва да е  $u(t) = U_{max}$  за да се получи максимално възможната акумулация на биомаса. В някакъв момент  $t_1$  (вж. Фиг. 97) управлението трябва да стане  $u(t) = 0$  докато стартира фазата на продуцирането в момента  $t = t_2$ . По време на фазата  $[t_1, t_2]$   $S$  намалява, докато в  $t = t_2$  стартира сингулярното управление на подхранването. Това сингулярно управление ще спре в някакво време  $t = t_3$  когато се изчерпи субстрата (или когато обемът на биореактора достигне крайната си стойност  $V(t_3) = V_f$ ). Ако има някакъв останал субстрат в биореактора, процесът може да продължи в периодичен режим ( $u = 0$ ) докато се изпълнят условията за спиране съобразно със съответната ЦФ в момента  $t = t_f$ .

**Случай 2:**  $S(0)$  е съизмеримо с  $S_{кр}$ , но  $S(0) < S_{кр}$  (това е реалистичния случай)

В този случай първият интервал  $[0, t_1]$  на подхранване с максимална скорост трябва да се пропусне (вж. Фиг. 97). Тогава фазата на растеж е напълно в периодичен режим докато в  $t = t_2$   $S$  е достатъчно малко и  $X$  е достатъчно голямо, за да стартира сингулярното подхранване.



Фиг. 97. Обща структура на оптималния профил



Фиг. 98б. Възможна структура на оптималния профил при голямо  $S(0)$

### Случай 3: $S(0)$ е върху сингулярното управление (рядко срещан случай)

В този случай фазата на растеж може да бъде напълно пропусната и сингулярното подхранване стартира от  $t = 0$ .

Определянето на сингулярното управление е доста трудно дори при наличие на добър детерминистичен модел, защото се изисква познаване както на състоянието на системата, така и на състоянието на спрегнатата система. В нашия случай може да се използват познати профили на сингулярното управление (от решаване на подобни задачи) и да се добави още една нова стъпка, в която при симулиране се заместват различни  $u_{sing}(t)$  (Фиг. 98б).

За определяне на оптималния подхранващ профил е приложена нелинейна оптимизация с ограничения. Използван е пакетът Optimization toolbox на Matlab и градиентният метод Sequential quadratic programming. Оптимизационната процедура намира минимум на ограничена нелинейна функция с няколко променливи. В оптимизационната процедура са използвани определените по предварителните симулационни изследвания граници на изменение на стойностите на променливите. По този начин се избягва получаването на оценки извън допустимите стойности и/или без физически смисъл.

## 5.1. Оптимизация на периодичен процес за получаване на ензим СОД при управляващо въздействие разтворен кислород

След направен анализ са възприети следните ЦФ:

$$1. \quad J_1 = -\frac{P}{t} \rightarrow \text{Min} \quad (125)$$

$$2. \quad J_2 = -\frac{P}{\int_0^t DO dt} \rightarrow \text{Min} \quad (126)$$

$$3. \quad J_3 = -\frac{P}{t + \int_0^t DO dt} \rightarrow \text{Min} \quad (127)$$

където  $P$  е ензимната активност,  $t$  е времето за протичане на процеса и  $DO$  е концентрацията на разтворения кислород. Първият критерий отразява желанието да се максимизира добивът на ензим за минимално време за протичане на процеса, докато във втория и третия е включена и енергетичната (икономическа) страна на процеса, т.е.

освен максимум ензим за минимум време, цели се също и минимални разходи за аериране на процеса.

Направени са симулационни изследвания с невронния модел при два вида входни въздействия: при постоянна концентрация на разтворен кислород и при концентрация на разтворен кислород, изменяща се по предварително зададен профил.

### Оптимизация при постоянна концентрация на разтворен кислород

Изследван е интервал от 20 до 50% концентрация на разтворен кислород, защото това е интервалът, за който разполагаме с експериментални данни за развитието на процеса. Не са разглеждани нива за  $DO$  повече от 50%, защото от експерименталните изследвания е установено, че процесът се влошава (при това и енергийните разходи стават много високи). Резултатите за добив на ензим и трите ЦФ-ии са представени в Табл. 43, а за  $J_1$ ,  $J_2$  и  $J_3$  – на Фиг. 99. Вижда се, че по критерий добив на ензим ( $J_1$ ) процесът е най-добър при  $DO = 50\%$ , като е препоръчително процесът да бъде спрян на 69-я час. По енергетичния критерий  $J_2$  процесът е най-добър при регулиране на  $DO = 30\%$ , а по критерий  $J_3$  – при регулиране на  $DO = 20\%$  (препоръчително спиране на 67-я час).

Таблица 43

| $DO$ [%]    | 20      | 30      | 40      | 50      |
|-------------|---------|---------|---------|---------|
| $P_{\max}$  | 103.88  | 156.79  | 196.24  | 214.0   |
| $t$ [h]     | 100     | 100     | 100     | 100     |
| $J_{1\min}$ | -1.48   | -2.06   | -2.45   | -2.69   |
| $t$ [h]     | 67      | 73      | 75      | 69      |
| $J_{2\min}$ | -5.19   | -5.23   | -4.91   | -4.28   |
| $t$ [h]     | 100     | 100     | 100     | 100     |
| $J_{3\min}$ | -0.0704 | -0.0666 | -0.0597 | -0.0527 |
| $t$ [h]     | 67      | 73      | 75      | 68      |

### Оптимизация при оптимален профил за концентрация на разтворен кислород

Изследвани са различни профили за поддържане на концентрация на разтворен кислород, като процесът е разделен условно на 3 фази:

1. От 0-вия до 30-я час на процеса. Това е фаза, отговаряща на общоприетата лаг-фаза. При нея не се наблюдава интензивно нарастване на биомасата, съответно няма интензивно дишане. През по-голямата част на тази фаза концентрацията на разтворен кислородът още не е спаднала под 20%. Достатъчно е да се поддържа  $DO = 20\%$ .

2. От 30-я до 60-я час на процеса. Това е фаза, отговаряща на общоприетата лог-фаза. Тя се характеризира с интензивно дишане и съответно интензивно нарастване на биомасата. Изследвани са нива на  $DO$  от 30% до 50%.

3. От 60-я до 100-я час на процеса. Концентрацията на ензим достига максимума си и след това започва деградацията му. Изследвани са нива на  $DO$  от 20% до 50%.

Резултатите за добив на ензим и трите ЦФ-ии за по-важните профили за концентрация на разтворен кислород са представени в Табл. 44 и 45, а за  $J_1$ ,  $J_2$  и  $J_3$  – на Фиг. 100. Според критерия  $J_1$  процесът е най-добър при профил 20/50/50%  $DO$ , като процесът трябва да бъде спрян на 81-я час. По енергетичен критерий  $J_2$  процесът е най-добър при профил 20/50/20%  $DO$ . Критерият  $J_2$  при профил 20/50/20%  $DO$  достига по-ниска стойност от минималното  $J_2$  за постоянно  $DO$ . По енергетичен критерий  $J_3$


процесът е най-добър при профил 20/30/40%  $DO$ , като почти достига минимума си за постоянно  $DO$ .

Таблица 44

| $DO$ [%]     | 20/50/20          | 20/50/30          | 20/50/40          | 20/50/50          |
|--------------|-------------------|-------------------|-------------------|-------------------|
| $t$ [h]      | 0-30/30-60/60-100 | 0-30/30-60/60-100 | 0-30/30-60/60-100 | 0-30/30-60/60-100 |
| $P_{\max}$   | 110.60            | 156.81            | 196.26            | 211.60            |
| $t_{P\max}$  | 59                | 100               | 92                | 100               |
| $J_{1\min}$  | -1.87             | -2.12             | -2.29             | -2.33             |
| $t_{J1\min}$ | 59                | 71                | 81                | 81                |
| $J_{2\min}$  | -5.53             | -5.23             | -4.91             | -4.23             |
| $t_{J2\min}$ | 60                | 100               | 92                | 100               |
| $J_{3\min}$  | -0.0523           | -0.0600           | -0.0614           | -0.0587           |
| $t_{J3\min}$ | 59                | 71                | 80                | 77                |


Таблица 45

| $DO$ [%]     | 20/30/40          | 20/30/50          | 20/40/30          | 20/40/40          |
|--------------|-------------------|-------------------|-------------------|-------------------|
| $t$ [h]      | 0-30/30-60/60-100 | 0-30/30-60/60-100 | 0-30/30-60/60-100 | 0-30/30-60/60-100 |
| $P_{\max}$   | 196.26            | 208.52            | 156.78            | 196.26            |
| $t_{P\max}$  | 98                | 100               | 100               | 95                |
| $J_{1\min}$  | -2.13             | -2.18             | -2.03             | -2.21             |
| $t_{J1\min}$ | 88                | 88                | 74                | 85                |
| $J_{2\min}$  | -4.91             | -4.17             | -5.23             | -4.91             |
| $t_{J2\min}$ | 98                | 100               | 100               | 95                |
| $J_{3\min}$  | -0.0697           | -0.0655           | -0.0653           | -0.0654           |
| $t_{J3\min}$ | 84                | 81                | 74                | 82                |



Фиг. 99.  $J_1$  — ,  $J_2$  — ,  $J_3 \cdot 10$  —

Като резултат от оптимизацията може да се направи извод, че ако се цели добив на ензим, е препоръчително да се поддържа високо ниво на кислородно насищане в биореактора (50%), като процесът се спре в 70-я час. Ако целта е икономия на енергия, по-подходящо е по-ниско ниво (20%). Най-добрият профил (едновременно добър по всички критерии) е профил 20/50/40%.



Фиг. 100.  $J_1$  — ,  $J_2$  — ,  $J_3 \cdot 10$  —

## 5.2. Оптимизация на полупериодичен процес за получаване на ензим СОД при управляващо въздействие концентрация на подхранваща глюкоза

След направен анализ са възприети следните ЦФ:

$$1. \quad J_1 = -\frac{P}{t} \rightarrow \text{Min} \quad (128)$$

$$2. \quad J_2 = -\frac{P}{t + \int_0^t S_{0i} dt} \rightarrow \text{Min} \quad (129)$$

$$3. \quad J_3 = -P + k_1 t + k_2 \int_0^t S_{0i} dt \rightarrow \text{Min} \quad (130)$$

където  $P$  е ензимната активност,  $t$  е времето за протичане на процеса и  $S_{0i}$  е концентрацията на добавената глюкоза. Първият критерий отразява добива на ензим за минимално необходимо време, докато във втория и третия е включена и икономическа страна на процеса, т.е. освен максимум ензим за минимум време, цели се също и минимални разходи за подхранване на процеса с глюкоза.

Направени са симулационни изследвания на хибридният модел при два вида входно въздействие: при постоянно  $S_{0i}$  и при  $S_{0i}$ , изменящо се по предварително зададен профил.

### Оптимизация при постоянна концентрация на подхранваща глюкоза

Изследван е интервал от 1 до 2 g/L за  $S_{0i}$ , защото това е интервалът, в който има увеличение на ензима при увеличаване на подхранването и за който разполагаме с експериментални данни за развитието на процеса. При по-големи стойности на  $S_{0i}$  се наблюдава инхибиране на процеса. Резултатите за добив на ензим и трите ЦФ-и са представени в Табл. 46, а за  $J_1$ ,  $J_2$  и  $J_3$  — на Фиг. 101. Вижда се, че и по трите критерия процесът е най-добър при подхранване 2 g/L, но е препоръчително процесът да бъде спряен по-рано. Тъй като минимумите на ЦФ-и  $J_1$  и  $J_2$  са на 28-29-я час, ако се цели оптимално количество ензим за минимум разходи, процесът би могъл да бъде спряен на 29-я час. Но тогава количеството ензим все още е много малко. Ако добвът на ензим натежава като фактор, то тогава се препоръчва спиране на процеса в 44-я час, където е максималният добив на ензим. Като резултат от оптимизацията може да се направи

извод, че най-добър резултат по всички показатели (висок добив на ензим и минимални разходи) дава критерии  $J_3$ , чийто минимум е в 40-я час и се препоръчва спиране на процеса в този момент.

Таблица 46

| $S_{0i}$ [g/L] | 1       | 1.25    | 1.5     | 1.75    | 2.0     |
|----------------|---------|---------|---------|---------|---------|
| $P_{\max}$     | 1770    | 1957.9  | 2215.6  | 2615.3  | 3666.5  |
| $t_{P\max}$    | 31      | 32      | 34      | 36      | 44      |
| $J_{1\min}$    | -71.1   | -74.4   | -79.4   | -87     | -101.5  |
| $t_{J1\min}$   | 20      | 22      | 23      | 25      | 29      |
| $J_{2\min}$    | -136.7  | -141.2  | -148.1  | -159.5  | -181.7  |
| $t_{J2\min}$   | 20      | 21      | 23      | 25      | 28      |
| $J_{3\min}$    | -1313.8 | -1432.3 | -1606.3 | -1895.9 | -2664.5 |
| $t_{J3\min}$   | 28      | 29      | 31      | 33      | 40      |

### Оптимизация при оптимален профил за концентрация на подхранваща глюкоза

Според теоретичните изследвания, за да се определи оптималният подхранващ профил, трябва да се определят следните показатели (Фиг. 97):

- времето  $t_2$
- подхранването  $u_{\text{sing}}$
- времето  $t_3$
- времето  $t_f$

Времето  $t_2$  е определено да бъде 12-ият час от началото на процеса, тъй като според експериментални данни за непрекъснат процес до този момент количеството глюкоза е намаляло, но не е изчерпано. За това всички опити с подхранване с глюкоза са проведени при подхранване, стариращо в 12-ия час.

Изследвани са различни профили за подхранване с глюкоза, като процесът е разделен условно на 3 фази:

1. От 0-вия до 12-ия час на процеса. През по-голямата част на тази фаза глюкозата в биореактора не се е изчерпала достатъчно, така че подхранване не е необходимо. Това е интервал  $[0, t_2]$  от Фиг. 97.

2. Фаза на подхранване – от 12-ия час на процеса до момент  $t_3$ , когато подхранването може да бъде спряно. Отговаря на интервал  $[t_2, t_3]$  от Фиг. 97. Това е фаза, характеризираща се с интензивно нарастване на биомасата и интензивно образуване на ензим, а глюкозата вече се е изчерпала, така че е нужно подхранване. Изследвани са различни профили на подхранване за различно време. За пълнота на изследването интервалът е разделен на два подинтервала:  $[t_2, t_{31}]$  и  $[t_{31}, t_3]$ , като във всеки от тях подхранването е различно (Фиг. 98б).

3. От  $t_3$  до края на процеса. Отговаря на интервал  $[t_3, t_f]$  от Фиг. 97 или на интервал  $[t_{32}, t_f]$  от Фиг. 98б. Изследванията показват, че подхранването може да бъде спряно преди края на процеса, без това да се отрази съществено на критериите.

Резултатите за добив на ензим и трите ЦФ-ии за по-важните подхранващи профили са представени в Табл. 47 и 48 и графично на Фиг. 102. Най-добри резултати и по трите критерия се получават за два подхранващи профила – 0/2/1/0 g/L и 0/2/0 g/L. Както и при постоянно подхранване, критериите  $J_1$  и  $J_2$  достигат минимума си на 28-29-

я час (препоръчват спиране на процеса в този час), когато все още няма достатъчно синтезиран ензим.

Най-добри резултати са получени при критерии  $J_3$ . При него се получава стартиране на подхранването в 12-я час ( $t_2 = 12$ ),  $S_{0i} = 2$  g/L, спиране на подхранването в 36-я час ( $t_3 = 36$ ) и спиране на процеса в 40-я час ( $t_f = 40$ ), защото тогава се минимизира критерият  $J_3$ .

Най-добрите подхранващи профили са показани на Фиг. 103, като оптималният е с червена линия. На Фиг. 104 са представени съответстващите им резултати от хибридният модел (за добив на ензим). Показани са също обработените експериментални данни при 2 g/L постоянно подхранване, които са използвани при обучението. Вижда се, че резултатите за добив на ензим са много близки, но при оптималния подхранващ профил времето за провеждане на процеса се скъсява с 45%, което води до големи икономии на разходи за провеждане и подхранване на процеса, като добивът на ензим се запазва.


Като резултат от оптимизацията може да се направи извод, че най-добър по всички показатели (висок добив на ензим и минимални разходи) е подхранващ профил 0/2/0, при който се започва подхранване с 2 g/L глюкоза в 12-я час, спира се подхранването в 36-я час, а процесът може да се спре в 40-я час, защото минимумът на критерия се достига в 40-я час.

Таблица 47


| $S_{0i}$ [g/L]  | 0/1/0            | 0/1/2/0                | 0/1/2/0                | 0/1/2/0                | 0/2/1/0                |
|-----------------|------------------|------------------------|------------------------|------------------------|------------------------|
| $t$ [h]         | 0-12/12-67/67-72 | 0-12/12-30/30-58/58-72 | 0-12/12-20/20-57/57-72 | 0-12/12-15/15-51/51-72 | 0-12/12-15/15-68/68-72 |
| $P_{\max}$      | 1770             | 1770.1                 | 2014.3                 | 2357.6                 | 2174                   |
| $t_{P_{\max}}$  | 31               | 32                     | 36                     | 36                     | 33                     |
| $J_{1\min}$     | -71.1            | -71.1                  | -71.1                  | -79                    | -81.5                  |
| $t_{J_{1\min}}$ | 20               | 20                     | 20                     | 25                     | 22                     |
| $J_{2\min}$     | -136.7           | -136.7                 | -136.7                 | -145.1                 | -153.9                 |
| $t_{J_{2\min}}$ | 20               | 20                     | 20                     | 24                     | 22                     |
| $J_{3\min}$     | -1313.8          | -1313.8                | -1353.0                | -1633.8                | -1653.2                |
| $t_{J_{3\min}}$ | 28               | 28                     | 30                     | 32                     | 30                     |

Таблица 48


| $S_{0i}$ [g/L]  | 0/2/1/0                | 0/2/1/0                | 0/2/1/0                | 0/2/0            | 0/2/0            |
|-----------------|------------------------|------------------------|------------------------|------------------|------------------|
| $t$ [h]         | 0-12/12-20/20-64/64-72 | 0-12/12-25/25-55/55-72 | 0-12/12-35/35-45/45-72 | 0-12/12-36/36-72 | 0-12/12-41/41-72 |
| $P_{\max}$      | 2659.9                 | 3090.9                 | 3574.6                 | 3594.2           | 3656.3           |
| $t_{P_{\max}}$  | 33                     | 36                     | 41                     | 40               | 43               |
| $J_{1\min}$     | -94                    | -100.3                 | -101.5                 | -101.5           | -101.6           |
| $t_{J_{1\min}}$ | 25                     | 27                     | 29                     | 29               | 29               |
| $J_{2\min}$     | -173.4                 | -181.7                 | -181.8                 | -181.7           | -181.7           |
| $t_{J_{2\min}}$ | 25                     | 27                     | 28                     | 28               | 28               |
| $J_{3\min}$     | -2061.7                | -2393.0                | -2675.5                | -2695.8          | -2664.5          |
| $t_{J_{3\min}}$ | 32                     | 34                     | 39                     | 40               | 40               |




Фиг. 101.  $J_1$  — ,  $J_2$  — ,  $J_3/10$  —



Фиг. 102.  $J_1$  — ,  $J_2$  — ,  $J_3/10$  —



Фиг. 103. Подхранващи профили ( — оптимален по  $J_3$  , — оптимални по  $J_1$  и  $J_2$  , — за максимален продукт)



Фиг. 104. Ензим СОД ( — оптимален по  $J_3$  , — оптимални по  $J_1$  и  $J_2$  , — за максимален продукт, \* реални експериментални данни)

### 5.3. Изводи

На базата на получените резултати могат да се дефинират следните изводи:

1. На основата на теоретични знания за оптималното управление на периодични биотехнологични процеси и с нелинейна оптимизация са определени оптимални профили по разтворен кислород на периодичен процес за получаване на вътреклетъчния ензим СОД при три критерия за оптималност.
2. На основата на теоретични знания за оптималното управление на полупериодични биотехнологични процеси и с нелинейна оптимизация са определени оптимални

профили за подхранването с глюкоза на полупериодичен процес за получаване на вътреклетъчния ензим СОД при три критерия за оптималност.

3. Препоръчва се подхранване на процеса с 2 g/L глюкоза, започващо в 12-я час, спиране на подхранването в 36-я час и спиране на процесът в 40-я час. При такъв профил времето за провеждане на процеса се скъсява с 45%, което води до големи икономии на разходи за провеждане и подхранване на процеса, като добивът на ензим се запазва.

## Приноси по дисертационния труд

1. Разработени са детерминистичен модел на периодичен процес за получаване на вътреклетъчния ензим СОД при използване на щам *H. lutea 103* и глюкозата като лимитиращ субстрат и невронен модел на същия процес с включване на разтворения кислород като управляващ вход с цел разработване на стратегия за оптимално управление на процеса.
2. Разработен е хибриден модел на полупериодичен процес за получаване на вътреклетъчния ензим СОД, при който специфичните скорости (на растеж на биомаса, консумация на субстрат и формиране на ензим) са моделирани с апарата на ИНМ с цел разработване на стратегия за оптимално управление на процеса.
3. На базата на диференциално-алгебричния подход са разработени нови наблюдатели на основните неизмерими променливи в тристъпален модел на анаеробното разграждане на органични отпадъци – специфичните скорости на растеж ( $\mu_1$  и  $\mu_2$ ) и концентрациите на биомасите ( $X_1$  и  $X_2$ ).
4. Разработени са нови невронни модели на процес за анаеробно разграждане на говежди тор. Обучението и верификацията са проведени с експериментални данни, получени от планиран експеримент с лабораторен анаеробен биореактор. Моделите могат да бъдат използвани за прогнозиране добива на биогаз при различни скорости на разреждане.
5. Разработен е невронен модел на процесите на анаеробно разграждане на активна утайка в каскада от два анаеробни биореактора. Моделът може да бъде използван за прогнозиране с една стъпка напред във времето на дебита на получавания биогаз в двата биореактора за различни скорости на разреждане.
6. Определени са оптимални профили по разтворен кислород (при периодичен процес за получаване на вътреклетъчния ензим СОД) и за подхранването с глюкоза (при полупериодичен процес получаване на ензима СОД) на основата на разработените модели.

## Публикации по дисертационния труд

1. Chorukova E., I. Simeonov, Neural and hybrid modelling of biotechnological processes, Studies in Informatics and Control Journal, 3, 2008, 305-314.
2. Simeonov I., E. Chorukova, Anaerobic digestion modelling with artificial neural networks, C.R. de BAS, Tome 61, 4, 2008, 505-512.
3. Chorukova E., S. Diop, I. Simeonov, On differential algebraic decision methods for the estimation of anaerobic digestion models, Lecture Notes in Computer Science, Springer-Verlag, 2007, 4545, 202-216.

4. Chorukova E, I. Simeonov, Neural model of the anaerobic digestion process in a cascade of two bioreactors, Proc. of Int. Conf. Automatics and Informatics'07, Sofia, October 3-6, 2007, III-43-III-46.
5. Чорукова Е., И. Симеонов, С. Пашова, Б. Спасова, Хибридно моделиране и оптимизация на полупериодичен биотехнологичен процес за получаване на ензима "супероксид дисмутаза", Мат. на межд. конф. „Автоматика и информатика'05", София, Октомври. 3-5, 2005, 193-196.
6. Simeonov I., E. Chorukova, B. Kalchev, Anaerobic digestion modelling with artificial neural networks, Proc. of 9th Int. Conf. "Computer Applications in Biotechnology", Nancy, France, March 28-31, 2004, 225-230.
7. Simeonov I., E. Chorukova, M. Angelova, Neural network modelling of a batch and fed - batch biotechnological process for superoxide dismutase production, Proc. of Int. Conf. "Automatics and Informatics'03", Sofia, October 6-8 , 2003, 207-210.
8. Chorukova E., Fed-batch process optimisation for the intracellular enzyme superoxide dismutase production, Bioautomation, 12, 2009, 13-20.

### **Ръководство на проекти в областта на дисертацията**

1. CTS "Aide au portage de projets européens", CNRS-LSS (Франция), Идентифицируемост и наблюдаемост на различни модели на процеса на анаеробно разграждане, базирано на алгебричната системна теория", 2006.
2. ФНИ, МУ-МИ-1603/2006, "Хибридно моделиране и управление на процеса на анаеробно разграждане на органични отпадъци от животновъдството".
3. ФНИ, МУ-И-1201/2002, "Моделиране и оптимизация на биотехнологичен процес за получаване на ензима супероксид дисмутаза с апарата на изкуствените невронни мрежи".

### **Участие в международни проекти в областта на дисертацията**

1. ЕБР, ИМ-БАН - CNRS-LSS (Франция), "Моделиране и управление на анаеробното разлагане на органични отпадъци в каскада от биореактори", Ръководители: ст.н.с. д-р Иван Симеонов и проф. Ерик Валтер, 2004-2006.
2. EURAID-ECONET, ИМ-БАН - LAGIS-Lille (Франция), Ръководители: ст.н.с. д-р Иван Симеонов и проф. Кристиан Васър, 2006-2007.

### **Цитирания в областта на дисертацията**

Simeonov I., E. Chorukova, B. Kalchev, Anaerobic digestion modelling with artificial neural networks, Proc. of 9th Int. Conf. "Computer Applications in Biotechnology", Nancy, France, March 28-31, 2004, 225-230.

1. Нойкова Н., П. Копринкова, Един хибриден подход за моделиране на микробната динамика на популации: пример за анаеробно пречистване на отпадни води, Екологично инженерство и опазване на околната среда, No 3, 2004, 59-66.