

DOI: <https://doi.org/10.15276/ict.02.2025.50>

УДК 004.8:519.8:681.518

Порівняльний аналіз підходів до моделювання невизначеності у діагностичних системах

Комлева Наталія Олегівна¹⁾

Канд. техніч. наук, доцент, завідувачка каф. Інженерії програмного забезпечення
ORCID: <http://orcid.org/0000-0001-9627-8530>; komleva@op.edu.ua. Scopus Author ID: 57191858904

¹⁾ Національний університет «Одеська політехніка», пр. Шевченка, 1. Одеса, 65044, Україна

АНОТАЦІЯ

У діагностичних системах, зокрема медичних, невизначеність є неминучою складовою, зумовленою неповнотою відомостей, похибками вимірювань, варіативністю симптомів та суб'єктивністю оцінок експертів. Традиційні детерміновані методи виявляються недостатніми для її моделювання, оскільки вони передбачають повну визначеність та однозначність даних. Тому актуальності набувають спеціальні підходи, які дозволяють працювати з різними типами невизначеності, зокрема імовірнісною, нечіткою та епістемічною. Найбільш поширеними серед них є нечітка логіка, байєсівський імовірнісний підхід та теорія Демпстера–Шейфера. Кожен із цих методів має власне теоретичне підґрунтя та забезпечує специфічні механізми обробки знань, що зумовило їхнє широке застосування в інтелектуальних системах.

У роботі проведено систематизований огляд і поглиблений порівняльний аналіз зазначених підходів. Розгляд здійснено за кількома критеріями: точність та чутливість діагностики, інтерпретованість результатів, вимоги до даних і знань, масштабованість та гнучкість до змін. Для нечіткої логіки ключовою є здатність формалізувати лінгвістично нечіткі поняття та працювати з градаціями істинності, що наближає процес обробки інформації до способу мислення експерта. Байєсівські мережі базуються на класичній теорії ймовірностей та дозволяють послідовно оновлювати знання за допомогою теореми Байєса. Вони є потужним інструментом для задач, у яких доступний значний обсяг статистичних даних і необхідна висока точність прогнозів. Теорія Демпстера–Шейфера, у свою чергу, забезпечує механізми об'єднання незалежних джерел інформації та надання інтервальних оцінок упевненості, що дозволяє ефективно працювати в умовах неповноти знань або конфліктних свідчень.

Результати проведеного аналізу підтверджують, що універсального методу роботи з невизначеністю не існує. Кожен підхід найбільш доцільний у своєму контексті: нечітка логіка – для задач із лінгвістично описовими даними, байєсівські мережі – для статистично обґрунтованих моделей, DST – для ситуацій з неповними чи суперечливими даними. Перспективним напрямом розвитку є побудова гібридних діагностичних систем, що поєднують різні методи моделювання невизначеності. Ідея полягає у створенні мультимодельних архітектур, де нечітка логіка відповідає за інтерпретацію якісних, лінгвістично описаних знань експертів, байєсівські мережі забезпечують імовірнісне обґрунтування висновків на основі статистичних даних, а теорія Демпстера–Шейфера дозволяє інтегрувати інформацію з кількох незалежних і навіть частково суперечливих джерел.

Ключові слова: діагностичні системи; штучний інтелект; моделювання невизначеності; нечітка логіка; байєсівські мережі; теорія Демпстера–Шейфера; обробка знань; прийняття рішень

Актуальність. У процесі діагностики систем (в тому числі, медичних) невизначеність є неминучою складовою. Неповнота відомостей про об'єкт діагностування, похибки вимірювань, варіативність симптомів та суб'єктивність оцінок – все це призводить до невизначеності при постановці діагнозу [1]. В умовах неоднозначних або неповних даних класичні детерміновані методи виявляються недостатніми – потрібні спеціальні підходи, здатні моделювати різні типи невизначеності у знаннях і даних. На сьогодні у діагностичних системах широко застосовуються три основні підходи до моделювання невизначеності: нечітка логіка, байєсівський підхід та теорія Демпстера–Шейфера. Кожен із цих підходів виник на різному теоретичному підґрунті та пропонує свій спосіб подання і обробки невизначених знань. Зокрема, нечітка логіка була розроблена для роботи з нечіткими, лінгвістично сформульованими поняттями та поступовими градаціями істинності, імовірнісний (байєсівський) підхід базується на класичній теорії ймовірностей та вважається універсальним математичним інструментом для усіх видів невизначеності, а теорія Демпстера–Шейфера розвинулася як узагальнення байєсівської теорії для врахування епістемічної невизначеності, тобто неповноти знань, і дозволяє оперувати ступенями довіри до гіпотез без потреби задавати точні ймовірності всіх альтернатив [2].

У даному дослідженні виконується огляд та поглиблений порівняльний аналіз зазначених трьох підходів моделювання невизначеності в діагностичних системах. Спочатку розглянуто концептуальні основи кожного підходу та їхнє застосування для діагностики.

Далі проведено порівняння їхніх можливостей, переваг і обмежень у типових сценаріях, зокрема на прикладі медичних діагностичних систем. Представлено практичні кейси використання кожного підходу та узагальнено результати у вигляді порівняльної таблиці основних характеристик. Це дозволяє окреслити рекомендації щодо вибору методу для фахівців у галузі моделювання, штучного інтелекту та інформаційних технологій.

Метою роботи є здійснення порівняльного аналізу трьох основних підходів до моделювання невизначеності – нечіткої логіки, байєсівського підходу та теорії Демпстера–Шейфера – у контексті діагностичних систем.

Для досягнення цієї мети поставлено такі завдання:

- надати огляд теоретичних основ кожного підходу та особливостей їх застосування для діагностики;
- проаналізувати переваги та обмеження (недоліки) кожного методу з точки зору забезпечення достовірності діагностики, вимог до даних, інтерпретованості результатів та обчислювальної складності;
- порівняти підходи між собою, виявивши сфери задач, де кожен із них найбільш доцільний або, навпаки, проблемний;
- сформулювати висновки і рекомендації щодо вибору або комбінування підходів при розробці діагностичних систем, з урахуванням специфіки задачі та характеру доступних даних.

Нечітка логіка – це підхід, що оперує поняттям нечітких множин і градієнтних (нечітких) значень істинності замість традиційних чітких (булевих) значень. В основі лежить ідея, запропонована Лотфі Заде у 1965 році, що багато реальних понять не мають різко окреслених меж – вони є розмитими, «фаззі». На відміну від класичної логіки, де вислів може бути тільки істинним або хибним, у нечіткій логіці висловлювання може бути істинним частково, з певним ступенем (від 0 до 1). Наприклад, твердження «температура тіла пацієнта висока» у класичній логіці було б або істинним, або ні, тоді як у нечіткій – може мати істинність 0.7, якщо температура 37.5°C, тобто «помірно висока». Таким чином, нечітка логіка дозволяє формалізувати лінгвістично нечіткі поняття (як-от «висока температура», «помірний біль», «значне поліпшення») та правила типу «Якщо X великий і Y помірний, то Z – низький», які часто зустрічаються в міркуваннях експертів-лікарів.

Моделювання невизначеності за допомогою нечіткої логіки відбувається через задання функцій приналежності для нечітких множин. Кожна лінгвістична змінна (наприклад, «температура» або «тиск крові») описується нечіткими підмножинами (як-от «низький», «нормальний», «високий»), які накладаються одна на одну. Функція приналежності відображає, наскільки конкретне значення належить до даної нечіткої категорії (ступінь від 0 до 1). Нечіткі правила типу «ЯКЩО [умова], ТО [висновок]» утворюють базу знань. Механізм нечіткого виведення (наприклад, алгоритм Мандані або Сугено) дозволяє на основі вхідних нечітких даних отримати нечіткі виходи, які потім переводяться у чітке значення рішення. В діагностичних системах на виході часто отримують оцінку ступеня ризику хвороби, діагностичну категорію або рекомендацію з лікування, представлену як нечітке значення, що потім інтерпретується експертом.

Переваги нечіткої логіки особливо помітні у ситуаціях, коли дані або знання носять розмитий, експертно-описовий характер.

По-перше, нечіткі моделі добре імітують стиль мислення людини-експерта, який оперує нечіткими поняттями. За допомогою нечіткої логіки можна природним чином включити до системи експертні правила, задані словесно, що підвищує інтерпретованість системи: фахівці розуміють, як приймається рішення, оскільки правила сформульовані зрозумілою мовою.

По-друге, нечіткі системи стійкі до шуму та часткової невизначеності даних: перехід між сусідніми станами плавний, а не стрибкоподібний, що забезпечує робастність до невеликих змін вхідних величин. Нечітка логіка дозволяє врахувати більше вхідних змінних без експоненційного зростання складності правил – завдяки тому, що правила формулюються на високому рівні абстракції (з використанням лінгвістичних термів). Також відзначається

відносна простота проєктування нечітких систем: інженер може створити працездатний прототип, навіть не маючи повного математичного опису об'єкта, а керуючись лише частковими знаннями і здоровим глуздом. Це пришвидшує розробку (метод «швидкого прототипування») і здешевлює систему порівняно з традиційними підходами, що вимагають детальних моделей. Важливо, що нечіткі системи добре опановують невизначеність та складність медичних діагностичних задач, покращуючи ефективність і точність діагностики в умовах неточних симптомів. Нечітка логіка нині є одним із найперспективніших підходів до побудови медичних експертних систем для роботи з невизначеними та нечіткими симптомами [3]. Більш того, комбінування нечіткої логіки з іншими методами (нейронними мережами, еволюційними алгоритмами тощо) породило цілий напрям «м'яких обчислень», які успішно застосовуються для діагностики складних станів – від аналізу сигналів ЕЕГ до прогнозування ризику хронічних хвороб.

Обмеження нечіткої логіки теж присутні. Найбільшим викликом є необхідність отримання повної та якісної експертної інформації для налаштування нечіткої системи. Для побудови бази правил та функцій приналежності потрібні знання від експертів про предметну область, причому ці знання мають бути узгоджені і формалізовані. Нечітка модель значною мірою відображає суб'єктивні уявлення експерта, тому успіх залежить від експертного налаштування. Практика показує, що складання повного набору правил, який покриває всі випадки, – непросте завдання; до того ж, відсутня гарантія, що розроблена експертами база правил буде оптимальною. Інша проблема – труднощі у верифікації та валідації нечіткої системи. Налаштовану систему доводиться багаторазово проганяти на різних сценаріях, підбираючи параметри функцій, щоб досягти належної точності. Відсутність формальних критеріїв оптимальності нерідко означає ітераційний процес «спроб і помилок» при доведенні системи до ладу. І хоча нечіткі системи працюють з математично нечіткими поняттями, в деяких наукових культурах (наприклад, у США) існує упередження проти таких «нестрогих» методів на користь традиційних статистичних моделей. Це стримує впровадження нечіткої логіки, хоча поступово ситуація змінюється завдяки успішним застосуванням.

Приклади застосувань нечіткої логіки в діагностиці охоплюють широкий спектр. У медицині розроблено багато нечітких експертних систем: зокрема, нечіткі діагностичні модулі для оцінки ризику серцево-судинних захворювань, діабету, онкологічних станів тощо. Одним із практичних кейсів є нечітка система діагностики захворювань щитоподібної залози, де правила формулюються на основі симптомів і результатів аналізів, представлених як лінгвістичні змінні (напр., «рівень гормону дещо підвищений») – така система успішно диференціювала кілька типів порушень функції щитоподібної залози [4]. Нечітка логіка також ефективно застосовується поза медициною – у технічній діагностиці. Зокрема, для діагностики несправностей складних пристроїв (автомобілів, авіадвигунів, промислових установок) будуються нечіткі діагностичні моделі, що інтерпретують розпливчасті ознаки несправностей (шум, вібрації, відхилення параметрів) та співставляють їм можливі причини. Завдяки толерантності до неточності даних, нечіткі діагностичні системи часто є більш надійними за традиційні порогові алгоритми. Загалом, нечітка логіка зарекомендувала себе як простий у реалізації та потужний інструмент, що підвищує гнучкість і точність діагностичних систем в умовах невизначеності.

Байєсівський підхід ґрунтується на використанні теорії ймовірностей для моделювання невизначених знань. Центральним є застосування теореми Байєса для оновлення ймовірностей гіпотез з урахуванням нових даних. У контексті діагностики байєсівський підхід зазвичай реалізується у формі байєсівських мереж – графових моделей, вузли яких представляють змінні (діагнози, симптоми, результати тестів), а ребра – причинно-наслідкові або кореляційні залежності між ними. Байєсівська мережа – це орієнтований ациклічний граф, кожен вузол якого наділений таблицею умовних ймовірностей станів вузла для кожної комбінації станів його батьківських вузлів. Така мережа визначає певний розподіл ймовірності на множині всіх змінних і дозволяє обчислювати апостеріорні ймовірності будь-

яких цікавих гіпотез (наприклад, захворювань) за заданих наявних даних (симптомів, аналізів) шляхом поширення ймовірності по графу [5]. Байєсівські мережі з'явилися як формалізм для графічного представлення і міркування при невизначеності, і відтоді стали широко застосовуватися не лише в медицині, а й в екології, фінансах, інженерії та багатьох інших сферах. У діагностичних системах вони природно виконують роль систем підтримки прийняття рішень: інтегруються в програмне забезпечення лікарень, консультаційні системи, допомагаючи лікарям оцінити ймовірність різних діагнозів та прогнозів [6].

Робота з невизначеністю у байєсівському підході відбувається шляхом задання апіорних ймовірностей гіпотез (до отримання даних) та правдоподібностей спостережуваних ознак (умовних ймовірностей ознак за умови наявності чи відсутності кожного діагнозу).

У випадку медичного діагностування коли надходять фактичні дані про пацієнта, використовується теорема Байєса:

$$P(H_i | D) = \frac{P(D | H_i) P(H_i)}{P(D)}, \quad (1)$$

де H_i – гіпотеза (наприклад, певне захворювання);

D – зібрані дані (симптоми, результати аналізів).

Таким чином обчислюються апостеріорні ймовірності гіпотез – оновлена невизначеність з урахуванням фактів. Якщо використовується байєсівська мережа, ці обчислення проводяться для всіх пов'язаних вузлів, часто за допомогою алгоритмів поширення довіри. Результатом є повний ймовірнісний розподіл на множині діагнозів, з якого можна обрати найбільш ймовірний або оцінити ризики.

Теорія Демпстера–Шейфера – це математичний апарат для моделювання епістемічної невизначеності, запропонований Артуром Демпстером і розвинений Гленном Шейфером як загальна теорія для роботи з довірою до різних гіпотез. На відміну від теорії ймовірностей, де потрібно задавати ймовірності конкретних гіпотез, DST дозволяє розподіляти міру довіри на підмножини множини можливих станів. Ця множина всіх гіпотез називається простором розрізнення. Функція, що задає розподіл довіри, називається базовою функцією маси (m): вона розподіляє одиницю маси по підмножинах простору (включно, можливо, з усією множиною і пустою множиною), причому сума мас = 1. Будь-яка конкретна гіпотеза отримує певну ступінь віри – суму мас всіх підмножин, які їй підмножини (підтримують цю гіпотезу повністю), та ступінь правдоподібності – суму мас підмножин, які не суперечать цій гіпотезі. Різниця між правдоподібністю і вірою відбиває міру невизначеності щодо гіпотези. Таким чином, DST надає інтервальну оцінку впевненості.

Нехай Θ – простір розрізнення (множина всіх можливих гіпотез). Два незалежні джерела інформації (наприклад, результати тестів чи експерти) задають функції мас:

$$m_1 : 2^\Theta \rightarrow [0, 1], m_2 : 2^\Theta \rightarrow [0, 1], \quad (2)$$

де m_i – це маса довіри (масова функція), яку i -те джерело надає підмножині $A \subseteq \Theta$.

Тоді правило комбінації Демпстера визначає об'єднану функцію мас:

$$m(A) = \frac{1}{1-K} \sum_{B \cap C = A} m_1(B) m_2(C), \quad \forall A \subseteq \Theta, A \neq \emptyset, \quad (3)$$

$$K = \sum_{B \cap C = \emptyset} m_1(B) m_2(C),$$

де $m(A)$ – нова маса довіри, яку отримує підмножина A після об'єднання доказів із двох джерел;

K – коефіцієнт конфлікту, який показує сумарну масу, що належить несумісним твердженням.

Якщо $K=0$, то докази повністю узгоджені, і формула зводиться до простого перемноження мас. Якщо $0 < K < 1$, то є певний рівень конфлікту; маси нормалізуються діленням на $1-K$, щоб відкинути суперечливу частину. Якщо $K \approx 1$, то докази майже повністю суперечливі, і об'єднання стає ненадійним.

Проведемо порівняльний аналіз підходів в залежності від точності, інтерпретованості, вимог до даних та гнучкості.

Точність та чутливість діагностики. Вибір підходу може впливати на здатність системи виявляти рідкісні або ранні стадії захворювань. Так, було відзначено, що нечітка логіка краще вловлює слабо виражені стани, яким відповідають низькі ймовірності, але ненульові ступені приналежності. Наприклад, на ранній стадії хвороби симптоми можуть бути ледь помітними (низька ймовірність постановки діагнозу за класичним підходом), проте нечітка система з відповідними правилами все ж видасть певний висновок з невисоким ступенем істинності, тоді як байєсівська – можливо проігнорує через низький апостеріорний шанс. З іншого боку, байєсівські мережі відмінно справляються з масивом сильних факторів ризику і симптомів, де на основі численних підтверджень вони акумулюють високу ймовірність ключового діагнозу. DST же покаже свою силу, коли частина ключових даних відсутня: замість штучного розподілу ймовірності вона залишить значну масу на «невідомість», що збереже діагностичну обережність і не «заспокоїть» лікаря неправдиво високою визначеністю.

Інтерпретованість і прозорість. За цим критерієм нечітка логіка має пріоритет – її правила зрозумілі експертам, а рішення можна пояснити, пославшись на спрацювавши правила (напр., «висока температура і помірний кашель => ризик грипу середній»). DST надає інтерпретацію у вигляді інтервалів довіри, що теж певною мірою зрозуміло: можна сказати «на основі даних, мінімальна впевненість у діагнозі 50%, але максимум може бути 90% якщо невідомості вирішаться на його користь». Це складніше, ніж один відсоток, але все ж лікар може зрозуміти концепцію «50–90%». Байєсівські мережі дещо менш прозорі для нефахівця, оскільки поєднують багато факторів одночасно. Хоча сама структура мережі (граф залежностей) – цілком інтерпретована і часто будується за причинними зв'язками, чисельні значення ймовірностей не так інтуїтивні, як словесні правила. Однак байєсівські мережі можуть пояснювати рішення шляхом обчислення внеску кожного доказу у кінцеву ймовірність – існують методики декомпозиції апостеріорних ймовірностей для пояснення, що теж покращує прозорість.

Гнучкість до змін та масштабування. Тут Bayesian-підхід виявляє певну слабкість: додавання нових гіпотез або нових змінних вимагає перегляду (репараметризації) всієї моделі, оскільки ймовірності повинні перенормуватися, додадуться нові залежності. DST легше розширюється: можна додати нову гіпотезу, просто додавши її до простору розрізнення і визначивши маси для неї – старі маси, якщо не змінюються, автоматично не потребують перерозподілу (хіба що порожня маса може зменшитись, якщо виділимо щось зі «невідомості» на нову гіпотезу). Нечітка логіка також дуже модульна: нове правило чи новий симптом можна додати незалежно, головне – щоб експерт визначив для нього функції приналежності. В плані обчислювальної масштабованості байєсівські мережі мають перевагу для великої кількості змінних, якщо структура розріджена: існують оптимізовані алгоритми на кшталт варіаційного виведення, що дозволяють обробляти сотні і тисячі змінних (наприклад, у генетиці) прийнятним часом. DST з тисячами гіпотез практично незастосовна (згадана експоненційна складність), а нечітка логіка з тисячами правил може стати хаотичною і важко керованою (хоча формально обчислення кожного правила окремо не є важким, але їх потрібно придумати і узгодити таку кількість). Тому по мірі зростання розміру задачі байєсівські моделі зазвичай перетягують пальму першості, особливо якщо є автоматизовані дані для навчання параметрів.

Вимоги до даних і знань. Підсумовуючи, нечітка логіка потребує експертних знань у явній формі (правила, лінгвістичні терми) та невеликого набору репрезентативних випадків для настройки функцій приналежності. Байєсівський підхід бажано забезпечити статистичними даними: апостеріорна точність сильно залежить від якості заданих ймовірностей, які найкраще оцінювати на основі великої вибірки. За відсутності великої вибірки, байєсівська модель покладається на суб'єктивні апіорні оцінки експертів, що може бути джерелом похибки, якщо експерти неточно їх зададуть. DST для успішної роботи

потребує незалежних джерел доказів (або методик оцінки залежності між джерелами, щоб не порушувати припущення незалежності) і хоча б приблизних оцінок достовірності кожного джерела (через функції мас). Якщо є багато даних, DST можна узгодити з імовірностями (наприклад, побудувати функцію маси з даних, розподіливши масу одиничним гіпотезам пропорційно їх ймовірностям, а певний залишок маси залишивши на універсальну множину як міру невідомості). Таким чином, DST може використовувати як дані, так і експертні оцінки; нечітка логіка – майже цілком експертні знання (дані – лише для тонкого налаштування, якщо є); байєсівський – або багато даних, або ретельно зібрані оцінки (часто обидва).

Сумісність і комбінування. Варто зазначити, що ці підходи не взаємовиключні. У сучасних діагностичних системах все частіше застосовуються гібридні моделі: наприклад, нечітко-байєсівські мережі, де деякі вузли мають нечіткі стани, або правила нечіткої логіки генерують вхідні ймовірнісні розподіли для байєсівської мережі. Так само DST можна накласти на виходи байєсівських класифікаторів для врахування ситуацій, коли класифікатор говорить «70 % клас А, 30 % клас В» – це можна інтерпретувати як функцію мас (0.7 на {А}, 0.3 на {В}) і об'єднати з іншими класифікаторами. Подібні мультимодельні підходи є трендом у галузі діагностики та прогнозування станів систем, оскільки дозволяють використати сильні сторони кожного методу [7, 8]. Наприклад, система прогнозування стану авіадвигуна може містити модуль байєсівської діагностики для стандартних режимів роботи та окремий DST-модуль для обробки сигналів від додаткових сенсорів у аварійних режимах – їхні виходи потім комбінуються. Інший приклад: медична система може використовувати байєсівську мережу для ймовірнісного виведення діагнозу на основі пацієнтських даних, але якщо даних недостатньо і мережа дає розподіл близько рівномірний, рішення приймається на користь «невідомо, потрібні додаткові обстеження» – це по суті DST-підхід, який визнає невизначеність замість примусового вибору.

Висновки. У діагностичних системах, які мають справу з невизначеними та неповними даними, правильний вибір методології моделювання невизначеності є критично важливим. Проведений аналіз трьох основних підходів – нечіткої логіки, байєсівського підходу та теорії Демпстера–Шейфера – показав, що кожен із них володіє унікальними можливостями і доцільний у своєму контексті. Головний висновок порівняльного аналізу – не існує універсально кращого підходу, натомість кожен метод доцільно застосовувати згідно з характером невизначеності та вимогами користувача. Якщо завдання передбачає багато нечітких, нечислових ознак і потребує пояснень – слід обрати або включити нечітку логіку. Коли є багатий масив даних і необхідна максимальна точність прогнозу – варто скористатися байєсівським ймовірнісним моделюванням. Коли інформація надходить від декількох експертів чи сенсорів і може бути суперечливою – доцільно використати теорію Демпстера–Шейфера для об'єднання доказів з оцінкою їх узгодженості. Для складних діагностичних систем оптимальною може бути мульти-модельна архітектура, що комбінує ці підходи: такі гібридні системи вже описані в літературі і показують кращу продуктивність, ніж кожен із методів окремо. Отже, компетентний підхід – це раціональне комбінування методів, керуючись природою задачі.

СПИСОК ЛІТЕРАТУРИ

1. Gürsel G. “Healthcare, uncertainty, and fuzzy logic”. *Digital Medicine*. 2016; 2 (3): 101–112. DOI: <https://doi.org/10.4103/2226-8561.194697>.
2. Verbert K., Babuska R., De Schutter B. “Bayesian and Dempster–Shafer reasoning for knowledge-based fault diagnosis – a comparative study”. *Engineering Applications of Artificial Intelligence*. 2017; 60: 136–150. DOI: <https://doi.org/10.1016/j.engappai.2017.01.011>.
3. Gupta N., Singh H., Singla J. “Fuzzy Logic-based Systems for Medical Diagnosis – A Review”. *Proceedings of the 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC)*. Coimbatore, India. 2022. p. 1058–1062. DOI: <https://doi.org/10.1109/ICESC54411.2022.9885338>.

4. Straszeka E. “A model of a diagnostic rule in the Dempster-Shafer theory”. In *Artificial Intelligence and Soft Computing – ICAISC 2006. Lecture Notes in Computer Science*. 2006; 4029: p. 998–1007. DOI: https://doi.org/10.1007/11785231_105.

5. Kyrimi E., et al. “A review of Bayesian networks in healthcare: application areas and challenges”. *Computational and Structural Biotechnology Journal*. 2021; 19: 4233–4254. DOI: <https://doi.org/10.1016/j.csbj.2021.07.013>.

6. Polotskaya K., et al. “Bayesian Networks for the Diagnosis and Prognosis of Diseases: A Scoping Review”. *AI*. 2022; 6 (2): 58. DOI: <https://doi.org/10.3390/ai6020058>.

7. Montero Jiménez J. J., et al. “Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics”. *Journal of Manufacturing Systems*. 2020; 56: 506–522. DOI: <https://doi.org/10.1016/j.jmsy.2020.07.006>.

8. Dong Y., Li X., Dezert J., Ge S. S. “Evidential reasoning with hesitant fuzzy belief structures for human activity recognition”. *IEEE Transactions on Fuzzy Systems*. 2021; 29 (5): 1322–1336. DOI: <https://doi.org/10.1109/TFUZZ.2020.2992852>.

DOI: <https://doi.org/10.15276/ict.02.2025.50>

УДК 004.8:519.8:681.518

Comparative analysis of approaches to uncertainty modeling in diagnostic systems

Nataliia O. Komleva¹⁾

PhD, Associate Professor, Head of the Software Engineering Department

ORCID: <http://orcid.org/0000-0001-9627-8530>; komleva@op.edu.ua. Scopus Author ID: 57191858904

¹⁾ Odesa Polytechnic National University, 1, Shevchenko Ave. Odesa, 65044, Ukraine

ABSTRACT

In diagnostic systems, particularly medical ones, uncertainty is an inevitable component caused by incomplete information, measurement errors, variability of symptoms, and the subjectivity of expert evaluations. Traditional deterministic methods prove insufficient for its modeling, as they assume complete certainty and unambiguity of data. Therefore, special approaches that allow working with different types of uncertainty, including probabilistic, fuzzy, and epistemic, are gaining relevance. The most common among them are fuzzy logic, the Bayesian probabilistic approach, and Dempster–Shafer theory. Each of these methods has its own theoretical foundation and provides specific mechanisms for knowledge processing, which has led to their widespread application in intelligent systems.

This study presents a systematized review and an in-depth comparative analysis of the mentioned approaches. The consideration was carried out according to several criteria: diagnostic accuracy and sensitivity, interpretability of results, requirements for data and knowledge, scalability, and flexibility to changes. For fuzzy logic, the key feature is the ability to formalize linguistically vague concepts and operate with gradual truth values, which brings the information processing process closer to the expert’s reasoning style. Bayesian networks are based on classical probability theory and allow sequential updating of knowledge through Bayes’ theorem. They are a powerful tool for tasks with a significant amount of statistical data available and where high predictive accuracy is required. Dempster–Shafer theory, in turn, provides mechanisms for combining independent sources of information and producing interval-valued confidence assessments, enabling effective operation under incomplete knowledge or conflicting evidence.

The results of the conducted analysis confirm that there is no universal method for handling uncertainty. Each approach is most appropriate in its own context: fuzzy logic for tasks with linguistically described data, Bayesian networks for statistically grounded models, and DST for situations with incomplete or conflicting data. A promising direction of development is the construction of hybrid diagnostic systems that combine different methods of uncertainty modeling. The idea lies in creating multi-model architectures where fuzzy logic is responsible for the interpretation of qualitative, linguistically described expert knowledge, Bayesian networks provide probabilistic justification of conclusions based on statistical data, and Dempster–Shafer theory enables the integration of information from several independent and even partially conflicting sources.

Keywords: Diagnostic systems; artificial intelligence; uncertainty modeling; fuzzy logic; Bayesian networks; Dempster–Shafer theory; knowledge processing; decision making