

修士論文

非線形学習を用いた環境騒音に 対する予測・評価に関する研究

平成 23 年度

三重大学大学院 工学研究科
博士前期課程 物理工学専攻

藤井 秀和

目次

第1章 序論	4
1.1 環境騒音の調査の現状と課題	4
1.2 先行研究とその課題	4
1.3 研究の目的	5
1.4 本論文の構成	5
第2章 学習・評価用データセットの説明	6
2.1 はじめに	6
2.2 環境基準（騒音）	6
2.3 環境騒音調査データベース	8
2.4 まとめ	9
第3章 短時間 L_{Aeq} から長時間 L_{Aeq} の予測	10
3.1 はじめに	10
3.2 先行研究と本研究の学習・評価用データセット	10
3.3 先行研究と本研究の目的	11
3.4 予測に試用した NN および SVM の構成	13
3.5 学習・予測結果	14
3.5.1 NN の予測結果	14
3.5.2 SVM の予測結果	19
3.5.3 NN と SVM の比較	24
3.6 まとめ	24
第4章 長時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測	25
4.1 はじめに	25
4.2 先行研究と本研究の目的	25
4.3 住民反応の予測と評価方法	28
4.4 予測に試用した NN 及び SVM の構成	28
4.4.1 個別反応の予測（個別予測）	28
4.4.2 反応割合の予測（集団予測）	28
4.5 学習・評価用データセット	29

4.6	個別反応の学習・予測結果	31
4.6.1	入力要素の検討(1)	31
4.6.2	入力要素の検討(2)	32
4.7	反応割合の学習・予測結果	33
4.8	先行研究との結果の比較	35
4.9	まとめ	37
第5章	短時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測	39
5.1	はじめに	39
5.2	NN および SVM の構成	39
5.3	学習・評価用データセット	40
5.4	正答率の学習・予測結果	40
5.5	反応割合の学習・予測結果	41
5.6	まとめ	45
第6章	総括	47
	謝辞	50
	参考文献・参考資料	51

第1章 序論

1.1 環境騒音の調査の現状と課題

国民が健康的な生活を営むには環境の整備・保護が重要であり、わが国ではそのために環境基本法 [1] が制定されている。この環境基本法に基づいて、道路建設や建物等の開発事業では環境への悪影響を防止するために、事業者には環境アセスメントの実施を義務付けている。アセスメントの対象項目には騒音も含まれており、一連の手続きの中で現況調査・予測・評価・事後調査が求められている。

また、事業アセスメントだけでなく、各自治体も行政区域内の環境の変化を把握するために、様々な環境要素を継続的に測定し、環境白書のような形で定期的に公表している。ここでも騒音は測定項目の一つとなっている。

このように環境騒音の測定は重要な意味を持つが、騒音の測定には多大な労力を必要とする上に人手や機材の数等の制約もあるので、多地点での測定を行う場合には、短時間の測定値から必要な長時間の騒音評価量を求めたいという実務上の要望が強い。

また、環境影響を評価する際、多くの環境アセスメントでは、測定した騒音評価量が環境基準を下回るか否かについてのみ判断（評価）が行われている。しかし、そのような2値的な判断だけでは、きめ細やかな対応はできないため、環境騒音を住民がどのように感じているかをアンケートなどにより調査することも考えられる。しかし、これにも大きな労力を要するため、騒音評価量から環境騒音に対する住民反応を予測することも重要な研究課題となっている。

1.2 先行研究とその課題

先行研究として、益村 [2] は短時間の騒音評価量から長時間の騒音評価量をニューラルネットワークモデルを用いて予測することを試みている。益村の作成したモデルでは、「地域類型」「観測月」「中心時刻」「時間長」「短時間 L_{Aeq} 」の5つの入力要素を用いているが、これらの要素が全て必要かどうかについては十分な検討がなされていない。一方、永野 [3] や吉田 [4] らは騒音評価量に基づいて環境騒音に対する住民反応をやはりニューラルネットワークモデルを用いて予測することを試みている。しかし、用地地域（商業区、工業区、住居区）別にモデルを構築しており、統一したモデルを作成するには至っていない。

また、予測する住民反応も、アンケートの回答そのものではなく陽性反応と陰性反応に集約した形式となっている。

1.3 研究の目的

上述のような背景から、本研究においても

- (1) 短時間の騒音評価量からの長時間の騒音評価量の予測
 - (2) 騒音評価量を用いた環境騒音に対する住民反応の予測
- について検討を加えるが、先行研究の内容や課題を踏まえて、以下のような目的を設定した。
- (a) いずれの先行研究もニューラルネットワークモデル (以下 NN) を用いていたが、新たに NN と同様、複雑なパターン認識に利用されるサポートベクトルマシン (以下 SVM) を用いたモデルを追加し、NN との違いについて調査する。
 - (b) (1) について先行研究のモデルの入力要素の組み合わせに再検討を加え、より簡略なモデルを作成する。
 - (c) (2) について先行研究のモデルについて、用途地域に依らない統合したモデルを作成し、アンケートの回答を直接予測させる。
 - (d) (2) に関して b) と c) を融合し、短時間の騒音評価量から住民反応を予測するモデルを構築する。

1.4 本論文の構成

次章以降の本論文の構成は以下の通りである。

第2章では環境基準や本研究で使った環境騒音調査のデータベースについて解説する。

第3章では短時間の騒音評価量からの長時間の騒音評価量の予測について述べる。(目的-(a)(b))

第4章では騒音評価量を用いた環境騒音に対する住民反応の予測について述べる。(目的-(a)(c))

第5章では短時間騒音評価量を用いた環境騒音に対する住民反応の予測について述べる。(目的-(a)(d))

第6章では本研究を総括する。

第2章 学習・評価用データセットの説明

2.1 はじめに

本章では環境騒音の評価法や本研究で NN や SVM の学習・評価に利用したデータベースの概略について概説する。

わが国では、環境行政の到達すべき目標値として大気汚染、水質汚濁、騒音、土壌汚染に関する環境基準が定められているが、ここでは騒音に関する基準について本研究に必要な範囲で解説する。

続いて、NN や SVM に予測能力を獲得させるには適切な学習（教師）データが必要である。本研究では久野らが 1982～1994 年に名古屋市内で収集した環境騒音調査データベース [5][6] を利用したので、その概要についても解説する。

2.2 環境基準（騒音）

現在、人の健康を保護し、また生活環境を保全するうえで維持されることが望ましい環境上の条件についての基準（環境基本法 16 条）が定められており、この基準を達成するために、排出規制、土地利用及び施設の設置に関する規制、公害防止に関する施設の整備、公害防止計画、環境影響評価（環境アセスメント）などの各種の施策が講じられている。環境基準は、こうした環境行政の到達すべき目標であって、それ自体として公害発生源に対しての法律的效果や最低限度・受忍限度の役割を果たすものではない。しかし、公害の防止に関する施策を総合的かつ有効適切に講ずることによって、この環境基準を確保する努力義務を政府が負っており、行政が行う環境調査や事業者の実施する環境アセスメントで目標値や参照値として多用されている。

本節では、この環境基準のうち、騒音に係る部分について用語の解説を含めて簡単に紹介する。

環境アセスメントで使用される騒音の環境基準は表 2.1 に示す通りである。表内の基準値は全て L_{Aeq} という騒音評価量である。 L_{Aeq} は人間の耳の感度特性を模した A 特性のフィルタを通した音のエネルギー平均値として定義されている [2]。

騒音に係る環境基準の特徴として以下の事項が挙げられる。

- 1 日を昼間（6:00～22:00）と夜間（22:00～翌 6:00）の 2 つの時間帯に分け、それぞれに基準値を設けている。
- 土地利用等に基づいて地域を AA から C までの 4 つの類型に分けており、環境騒音基準値は 3 通りに設定されている。
- 道路に面する地域はそれ以外の一般地域とは別に基準が設けられている。
- さらに特例として幹線道路に近接する空間が設定されており、これに対しては屋内基準も別に定められている。

このように環境基準は地域類型別に 1 日を昼夜の 2 時間帯に分けて定義されており、それぞれ 16 時間と 8 時間全体の騒音を測定・評価する必要がある。また、騒音は天候や社会活動の変化の影響も大きく受けるため、測定対象として平均的な日の値を得ようとする と多大な労力を要することになる。

表 2.1: 騒音にかかる環境基準の基準値 [7][8]

(a)一般地域

地域の類型	該当地域	時間の区分	
		昼間（6:00～22:00）	夜間（22:00～6:00）
AA	特に静穏を要する地域	50dB 以下	40dB 以下
A	住居専用地域	55dB 以下	45dB 以下
B	住居地域		
C	商業系地域及び工業系地域	60dB 以下	50dB 以下

(b)道路に面する地域

地域の区分	時間の区分	
	昼間（6:00～22:00）	夜間（22:00～6:00）
A 地域のうち 2 車線以上の車線を有する道路に面する地域	60dB 以下	55dB 以下
B 地域のうち 2 車線以上の車線を有するか、C 地域のうち車線を有する道路に面する地域	65dB 以下	60dB 以下
特例 幹線道路に近接する空間	70dB 以下 [45dB 以下]	65dB 以下 [40dB 以下]

注：[] 内は屋内基準

なお、現在使用されている1日の環境基準は新基準である。現在の環境基準が施行されたのは1999年4月1日である。新・旧基準との大きな違いは1日の環境基準の時間帯である。新基準は上で述べたように昼間と夜間の2時間帯であり、旧基準は朝、昼間、夕方、夜の4時間帯である。騒音に係る環境基準(新・旧)を表4.5に示す。なお、夜間については新・旧基準とも同じである。

表 2.2: 騒音に係る環境基準の時間帯

新基準	昼間	6:00 ~ 22:00	$L_{Aeq,D}$
新基準	夜間	22:00 ~ 6:00	$L_{Aeq,N}$
旧基準	朝	6:00 ~ 8:00	$L_{Aeq,M}$
旧基準	昼間	8:00 ~ 19:00	$L_{Aeq,D'}$
旧基準	夕方	19:00 ~ 22:00	$L_{Aeq,E}$

2.3 環境騒音調査データベース

本研究で使用した環境騒音調査データベースの内容を表2.3に示す。このデータベースは研究者らが協力して収集した1982~1994年の名古屋市域のものである。その調査方法は住居の環境騒音の計測と同時に住民の生活環境調査(聞き取りによるアンケート調査)を行うものであった。騒音測定については、住居の環境騒音を代表すると思われる地点(軒下、ベランダの手すり、植え込み等)に自動記録型騒音計を設置して平日に昼夜連続測定を行い、1日分、計144個の10分ごとの L_{Aeq} と L_{50} を収録している。住民の生活環境調査については、住居とその周辺状況、回答者の属性と騒音に関する意識を調査して回答を得ている。

表 2.3: 生活環境調査と二次データの主な内容

騒音暴露量の測定	$L_{Aeq,1/6h}$ 144 個 (一日 24 時間にわたる 10 分間毎の等価騒音レベル) 測定年月日, 開始時刻 測定器番号, 設置位置 天候
生活環境調査	メッシュコード 面談した住人の属性 (性別, 年齢, 職業, 家族構成) 住居の形態, 窓枠の構造, 鉄道, 工場, 飛行場, 住居地域, 用途地域, 建物密集度など) 住居年数, 住み心地 騒音に対する反応 (自宅周辺及び自宅内) 騒音源など
二次データ (騒音評価量)	$L_{Aeq,24h}$: 一日 (24 時間) の等価騒音レベル L_{dn} : 一日の昼・夜別重み付きの等価騒音レベル ⁽¹⁾ L_{den} : 一日の昼・夕・夜別重み付きの等価騒音レベル ⁽²⁾ $L_{Aeq}(\text{朝}) = L_{AeqM}$: 6:00-8:00 の $L_{Aeq,2h}$ $L_{Aeq}(\text{昼}) = L_{AeqD}$: 8:00-19:00 の $L_{Aeq,11h}$ $L_{Aeq}(\text{夕}) = L_{AeqE}$: 19:00-22:00 の $L_{Aeq,3h}$ $L_{Aeq}(\text{夜}) = L_{AeqN}$: 22:00-6:00 の $L_{Aeq,8h}$ $L_{Aeq,1/6}^{(@)} = L_{Aeq,1/6}$ の @% 値 (@ = 10, 50, 90) L_{50} : 144 個の $L_{50,10min}$ の算術平均値(注) L_{50dn} : 一日の昼・夜別重み付きの L_{50} の算術平均 L_{50den} : 一日の昼・夕・夜別重み付き算術平均 $L_{50}(\text{朝}) = L_{50M}$: 6:00 - 8:00 の L_{50} の算術平均 $L_{50}(\text{昼}) = L_{50D}$: 8:00 - 19:00 の L_{50} の算術平均 $L_{50}(\text{夕}) = L_{50E}$: 19:00 - 22:00 の L_{50} の算術平均 $L_{50}(\text{夜}) = L_{50N}$: 22:00 - 6:00 の L_{50} の算術平均 など

(1) 22:00 - 7:00 の $L_{Aeq,9h}$ または L_{50} の平均値に 10dBA のペナルティを付加

(2) 19:00 - 22:00 の $L_{Aeq,3h}$ または L_{50} の平均値に 5dBA のペナルティを付加

(注) L_{50} に関する二次データは 1987 年以降収録

2.4 まとめ

本章では、本研究で取り扱う、環境騒音の評価法やデータベースについて解説した。3 章以降の NN や SNM の学習・評価では、本章で解説したデータベースから必要なデータを抽出して、新たにデータセットを作成している。これら詳細については各章で解説する。

第3章 短時間 L_{Aeq} から長時間 L_{Aeq} の予測

3.1 はじめに

実務上、短時間の計測で得られる騒音評価量から環境アセスメント評価に使用される長時間の騒音評価量を求めたいという潜在的ニーズがあるため、本章では NN および SVM で短時間 L_{Aeq} から長時間 L_{Aeq} を予測することを試みる。

3.2 先行研究と本研究の学習・評価用データセット

まず、NN の入力要素は「地域類型」「観測月」「中心時刻」「時間長」「短時間 L_{Aeq} 」の 5 つである。「地域類型」は測定地点からの幹線道路までの距離、用途地域などの情報を用いて、図 3.1 に従い、8 通りに分けている。地域類型の特徴として以下の事項が挙げられる。

- A 地域は住居専用地域、B 地域は住居地域、C 地域は商業系地域および工業系地域である。
- A 地域、B 地域および C 地域は道路に面する地域とそれ以外の地域に分けられており、A 地域と B 地域は 2 車線以上の道路、C 地域は 1 車線以上の道路までの距離が 20m 以下を道路に面する地域とした。

また、幹線道路までの距離が 20m 以下の地域を本論文では近接空間と呼ぶことにする。「観測月」は測定を何月に行ったのかを、「中心時刻」と「時間長」は「短時間 L_{Aeq} 」を得た時間帯と時間長を表わしている。「時間長」は 1～6 時間の 6 通りである。また、昼間の「中心時刻」は 1 地点あたりのデータ数を夜間のデータ数と等しくするため、社会活動が安定している時間帯として 10～18 時の間を選んだ。出力要素は昼間または夜間の長時間 L_{Aeq} の予測値である。

NN と SVM の学習・評価には 2051 地点のデータを学習用と評価用に 2 つに分ける必要があり、地域類型と観測月の組み合わせが学習データと評価データで大きく変わらないように 2 分した。本研究は先行研究 [2] と同じ学習・評価データを使用している。

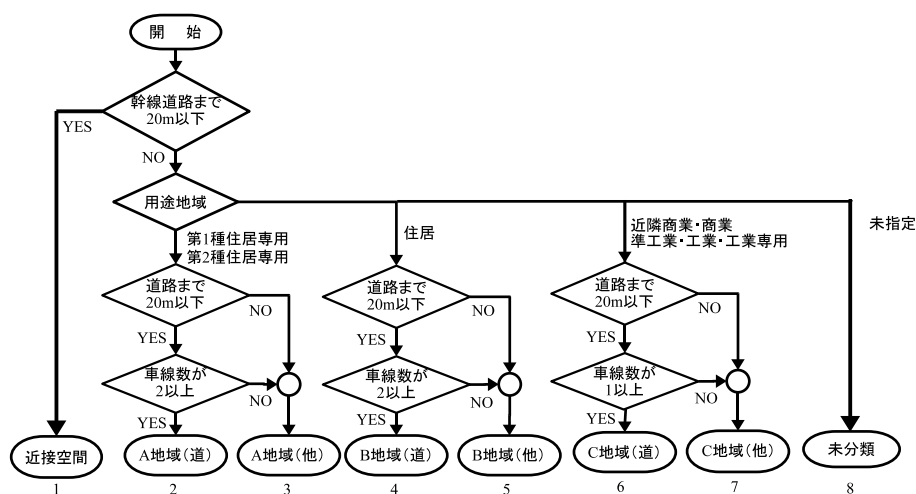


図 3.1: 地域類型の分類フロー図

3.3 先行研究と本研究の目的

目的が同じ NN を利用した先行研究があるので、本研究ではその入力要素の見直しに加え、新たに SVM による予測を行い、NN による結果と比較する。先行研究 [2] で使用された NN の構成を図 3.2 に示す。なお、入力要素は-1 ~ 1 になるように規格化を行った。学習には Kick-out 法 [9] を利用している。

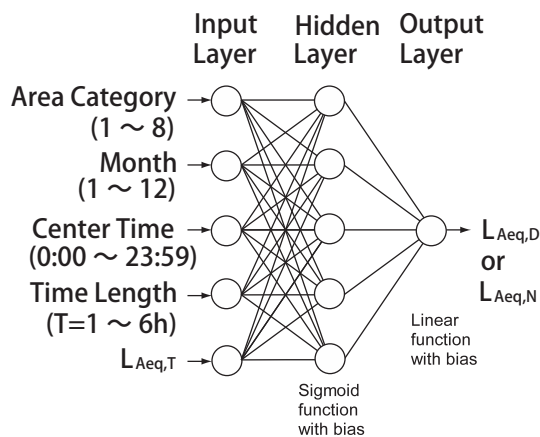


図 3.2: 先行研究の NN の構成

本研究と同じ環境騒音調査データベースを用いて 5000 回の学習を行ったときの学習・評価誤差は表 3.1 の通りであった。学習・評価データ全体の RMS 誤差は 3dB 以内に収まっている。

表 3.1: 5 入力 of NN の学習・評価誤差

データ区分	RMS 誤差
昼間・学習 [dB]	2.41
昼間・評価 [dB]	2.55
夜間・学習 [dB]	2.74
夜間・評価 [dB]	2.96

昼間の時間長別の学習・評価誤差を図 3.3 に示す。時間長が長くなるほど誤差は小さくなり、近接空間の予測誤差はデータ全体のものより小さい。中心時刻別の評価誤差を図 3.4 に示す。ただし、使用するデータは時間長が 1 時間のものに限定した。学習・評価データ全体の予測誤差はどの時間帯においても 3dB 前後である。近接空間の予測誤差はどの時間帯においても学習・評価データ全体のものよりも小さい。




図 3.3: 先行研究の昼間の予測誤差




図 3.4: 先行研究の昼間の予測誤差

夜間の時間長別の学習・評価誤差を図 3.5 に示す。昼間の予測と同様に時間長が長くなるほど誤差は小さくなり、近接空間の予測誤差はデータ全体のものより小さい。しかし、昼間の学習・評価誤差よりも誤差は大きくなる。夜間の中心時刻別の評価誤差を図 3.6 に示す。ただし、使用するデータは時間長が 1 時間のものに限定した。どの場合においても中心時刻が 3.5 時のときに最も予測誤差が大きくなる。




図 3.5: 先行研究の夜間の予測誤差




図 3.6: 先行研究の夜間の予測誤差

3.4 予測に試用した NN および SVM の構成

本研究で使用した NN ならびに SVM の構成はそれぞれ図 3.7、図 3.8 に示す通りである。先行研究よりも 1 入力減らして予測し、短時間 L_{Aeq} 以外の入力要素が予測に与える影響を考察する。ただし、SVM については先行研究の 5 つの入力要素を用いて予測する場合も考察する。

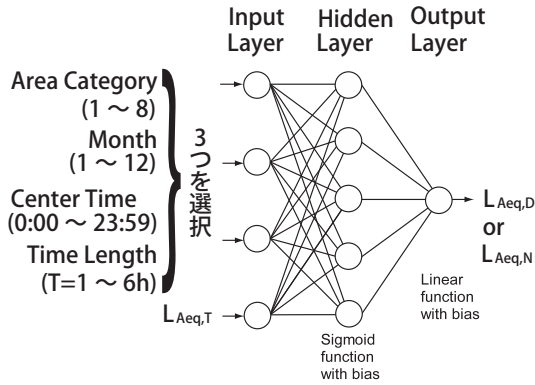


図 3.7: 3 章の NN の構成




図 3.8: 3 章の SVM の構成

なお、これらの入力要素は NN では $-1 \sim 1$ 、SVM では $0 \sim 1$ になるように正規化を行った。NN の学習法には先行研究と同じ Kick-out 法を利用した。SVM の構成は入力要素、出力要素は NN と等しいが、中間層の素子数はアルゴリズムにより自動で決定される。この研究に用いた SVM のカーネル関数は $\sigma = \omega = 1$ の Puk カーネルである。 $\sigma = \omega = 1$ の Puk カーネルは次の式で表わされる。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \frac{1}{1 + \left(2\sqrt{\|\mathbf{x}_i - \mathbf{x}_j\|^2}\right)^2}$$

ここで、 \mathbf{x}_i は $0 \sim 1$ に正規化された i 番目の入力ベクトルで、 \mathbf{x}_j は $0 \sim 1$ に正規化された j 番目のサポートベクトルである。また、SVM の複雑さを決定するパラメータ C の値は 1 とした。一般的に、 C の値が大きいくほど学習された SVM の出力関数は複雑になり、学習時間も長くなる。

SVM の学習・評価には WEKA[10] というソフトウェアを用い、学習法として SMO[11] を選択した。

3.5 学習・予測結果

3.5.1 NN の予測結果

上記で示した4入力NNの学習・評価誤差は表3.2のようになった。表中の()内の数値は先行研究の学習・評価誤差との差である。正の値のものは先行研究の学習・評価誤差よりも誤差が大きくなったことを、負の値のものは先行研究の学習・評価誤差よりも誤差が大きくなったことを表わす。地域分類がない場合と観測月がない場合は5入力のNNに比べて昼夜間ともに学習・評価誤差がわずかに小さい。

表 3.2: NN の学習・評価誤差

データ区分	地域分類なし	観測月なし	中心時刻なし	時間長なし
昼間・学習 [dB]	2.40(-0.01)	2.39(-0.02)	2.38(-0.03)	2.41(0.00)
昼間・評価 [dB]	2.53(-0.02)	2.52(-0.03)	2.51(-0.04)	2.55(0.00)
夜間・学習 [dB]	2.68(-0.06)	2.67(-0.07)	2.82(+0.08)	2.74(0.00)
夜間・評価 [dB]	2.93(-0.03)	2.92(-0.04)	3.02(+0.06)	2.97(+0.01)

次に、先行研究と本研究の昼間の予測誤差を時間長別と中心時刻別に比較するためにそれぞれの入力要素の組み合わせで予測した時の誤差を先行研究の方法で予測した時の誤差で引いたものを図示する。ただし、中心時刻別の予測誤差の比較は時間長が1時間のデータのみを使用した。また、グラフの負の値は本研究の予測誤差の方が先行研究のものより小さいことを表わしている。

まず、時間長別の結果を示す。

- 昼間・地域類型なしの時間長別の結果は図3.9である。データ全体の学習・評価誤差は先行研究のものより小さくなったが、近接空間の学習・評価誤差は時間長が1～3時間の場合に先行研究のものより大きくなった。
- 昼間・観測月なしの時間長別の結果は図3.11である。データ全体の学習・評価誤差は先行研究のものより小さくなったが、近接空間の評価誤差は時間長が1時間と6時間の場合に先行研究のものより大きくなった。
- 昼間・中心時刻なしの時間長別の結果は図3.13である。データ全体の学習・評価誤差は先行研究のものより小さくなったが、近接空間の評価誤差は時間長が1時間と6時間の場合に先行研究のものより大きくなった。
- 昼間・時間長なしの時間長別の結果は図3.15である。データ全体と近接空間の学習・評価誤差ともに先行研究のものより大きくなる時間長があった。

これらの結果から入力要素から時間長を除くのは良くない。なぜなら、時間長なしの予測ではデータ全体の学習・評価誤差が先行研究のものより大きくなるからである。

次に、中心時刻別の結果を示す。

- 昼間・地域類型なしの中心時刻別の結果は図 3.10 である。中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差ともに先行研究のものより大きくなった。
- 昼間・観測月なしの中心時刻別の結果は図 3.12 である。中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差ともに先行研究のものより大きくなった。
- 昼間・中心時刻なしの中心時刻別の結果は図 3.14 である。中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差ともに先行研究のものより大きくなった。
- 昼間・時間長なしの中心時刻別の結果は図 3.16 である。中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差ともに先行研究のものより大きくなった。





図 3.9: 昼間・地域類型なしの予測誤差の比較 図 3.10: 昼間・地域類型なしの予測誤差の比較





図 3.11: 昼間・観測月なしの予測誤差の比較 図 3.12: 昼間・観測月なしの予測誤差の比較





図 3.13: 昼間・中心時刻なしの予測誤差の比較 図 3.14: 昼間・中心時刻なしの予測誤差の比較





図 3.15: 昼間・時間長なしの予測誤差の比較 図 3.16: 昼間・時間長なしの予測誤差の比較

夜間の結果も昼間と同様に、先行研究と本研究の予測誤差を時間長別と中心時刻別に比較した。時間長別の結果から示す。

- 夜間・地域類型なしの時間長別の結果は図 3.17 である。データ全体の学習・評価誤差は先行研究のものより小さくなったが、近接空間の評価誤差は時間長が 1 時間と 2 時間の場合に先行研究のものより大きくなった。
- 夜間・観測月なしの時間長別の結果は図 3.19 である。近接空間の評価誤差は時間長が 1 時間の場合に先行研究のものより大きくなった。しかし、それ以外は全て先行研究の学習・評価誤差より小さくなっていた。
- 夜間・中心時刻なしの時間長別の結果は図 3.21 である。時間長が 1～3 時間の場合に、データ全体と近接空間の学習・評価誤差が先行研究のものより大きくなった。
- 夜間・時間長なしの時間長別の結果は図 3.23 である。データ全体の学習・評価誤差と近接空間の評価誤差は時間長が 1 時間と 6 時間の場合に先行研究のものより大きくなった。

これらの結果から入力要素から中心時刻と時間長を除くのは良くない。なぜなら、中心時刻なしの予測と時間長なしの予測はデータ全体の学習・評価誤差は先行研究のものより大きくなるからである。

次に、中心時刻別の結果を示す。

- 夜間・地域類型なしの結果は図 3.18 である。中心時刻が 0.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものより小さくなった。
- 夜間・観測月なしの結果は図 3.20 である。中心時刻が 0.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものより小さくなった。
- 夜間・中心時刻なしの結果は図 3.22 である。中心時刻が 0.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものより小さくなった。
- 夜間・時間長なしの結果は図 3.24 である。中心時刻が 0.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものより小さくなった。





図 3.17: 夜間・地域類型なしの予測誤差の比較 図 3.18: 夜間・地域類型なしの予測誤差の比較





図 3.19: 夜間・観測月なしの予測誤差の比較 図 3.20: 夜間・観測月なしの予測誤差の比較





図 3.21: 夜間・中心時刻なしの予測誤差の比較 図 3.22: 夜間・中心時刻なしの予測誤差の比較





図 3.23: 夜間・時間長なしの予測誤差の比較 図 3.24: 夜間・時間長なしの予測誤差の比較

3.5.2 SVM の予測結果

既存研究と同じ5つの入力要素を用いたSVMで予測した場合の学習・評価誤差は表3.3のようになった。表中の()内の数値は先行研究の学習・評価誤差との差である。正の値のものは先行研究の学習・評価誤差よりも誤差が大きくなったことを、負の値のものは先行研究の学習・評価誤差よりも誤差が大きくなったことを表わす。昼夜間ともに評価誤差はRMS 誤差で0.03dB 程度しか小さくならない。

表 3.3: SVM の学習・評価誤差

データ区分	5 入力	地域分類なし	観測月なし	中心時刻なし	時間長なし
昼間・学習 [dB]	2.25(-0.15)	2.39(-0.02)	2.34(-0.07)	2.28(-0.13)	2.29(-0.12)
昼間・評価 [dB]	2.58(+0.03)	2.59(+0.04)	2.55(0.00)	2.59(+0.04)	2.64(+0.09)
夜間・学習 [dB]	2.45(-0.29)	2.57(-0.17)	2.56(-0.16)	2.70(-0.04)	2.51(-0.23)
夜間・評価 [dB]	2.92(-0.04)	2.88(-0.08)	2.90(-0.06)	3.13(+0.17)	3.02(+0.06)

先行研究と本研究の昼間の予測誤差を時間長別と中心時刻別に比較するためにそれぞれの入力要素の組み合わせで予測した時の誤差を先行研究の方法で予測した時の誤差で引いたものを図示する。ただし、中心時刻別の予測誤差の比較は時間長が1時間のデータのみを使用した。また、グラフの負の値は本研究の予測誤差の方が先行研究のものより小さいことを表わしている。

まず、時間長別の結果を示す。

- 昼間・5 入力の結果は図 3.25 である。データ全体と近接空間の学習誤差は先行研究のものより小さくなったが、データ全体と近接空間の評価誤差は先行研究のものより大きくなった。
- 昼間・地域類型なしの結果は図 3.27 である。データ全体と近接空間の学習誤差は先行研究のものより小さくなったが、データ全体の評価誤差は先行研究のものより大きくなった。
- 昼間・観測月なしの結果は図 3.29 である。データ全体と近接空間の学習誤差は先行研究のものより小さくなったが、データ全体と近接空間の評価誤差は先行研究よりも大きくなった時間長がある。
- 昼間・中心時刻なしの結果は図 3.31 である。データ全体と近接空間の学習誤差は先行研究のものより小さくなったが、データ全体と近接空間の評価誤差は先行研究よりも大きくなった時間長がある。

- 昼間・時間長なしの結果は図 3.33 である。データ全体と近接空間の学習誤差は先行研究のものより小さくなったが、データ全体と近接空間の評価誤差は先行研究よりも大きくなった時間長がある。

次に、中心時刻別の結果を示す。

- 昼間・5 入力の結果は図 3.26 である。NN の場合と異なり、中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものよりも小さくなった。
- 昼間・地域類型なしの結果は図 3.28 である。NN の場合と異なり、中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものよりも小さくなった。
- 昼間・観測月なしの結果は図 3.30 である。NN の場合と異なり、中心時刻が 12.5 時の場合にデータ全体と近接空間の学習・評価誤差は先行研究のものよりも小さくなった。
- 昼間・中心時刻なしの結果は図 3.32 である。データ全体の学習・評価誤差は中心時刻が 12.5 じの場合に、近接空間の学習・評価誤差は中心時刻が 10.5 時の場合に先行研究のものより大きくなった。
- 昼間・時間長なしの結果は図 3.34 である。データ全体と近接空間の評価誤差は時間長によらず、先行研究よりも大きい傾向にあった。




図 3.25: 昼間・5 入力 of 予測誤差の比較




図 3.26: 昼間・5 入力 of 予測誤差の比較




図 3.27: 昼間・地域類型なし of 予測誤差の比較




図 3.28: 昼間・地域類型なし of 予測誤差の比較




図 3.29: 昼間・観測月なし of 予測誤差の比較




図 3.30: 昼間・観測月なし of 予測誤差の比較




図 3.31: 昼間・中心時刻なし of 予測誤差の比較




図 3.32: 昼間・中心時刻なし of 予測誤差の比較





図 3.33: 昼間・時間長なしの予測誤差の比較 図 3.34: 昼間・時間長なしの予測誤差の比較

夜間の結果も昼間と同様に、先行研究と本研究の予測誤差を時間長別と中心時刻別に比較した。時間長別の結果から示す。

- 夜間・5 入力の結果は図 3.35 である。データ全体と近接空間の学習・評価誤差は時間長によらず、先行研究のものより小さくなる傾向にあった。
- 夜間・地域類型なしの結果は図 3.37 である。データ全体と近接空間の学習・評価誤差は時間長によらず、先行研究のものより小さくなった。
- 夜間・観測月なしの結果は図 3.39 である。データ全体と近接空間の学習・評価誤差は時間長によらず、先行研究のものより小さくなった。
- 夜間・中心時刻なしの結果は図 3.41 である。データ全体と近接空間の評価誤差は時間長によらず、先行研究のものより大きくなる傾向にあった。
- 夜間・時間長なしの結果は図 3.43 である。データ全体と近接空間の評価誤差は時間長によらず、先行研究のものより大きくなる傾向にあった。

次に、中心時刻別の結果を示す。

- 夜間・5 入力の結果は図 3.36 である。データ全体と近接空間の学習・評価誤差は中心時刻によらず、先行研究のものより小さくなる傾向にあった。
- 夜間・地域類型なしの結果は図 3.38 である。近接空間の評価誤差は中心時刻が 22.5 時と 4.5 時の場合に先行研究のものに比べて最も大きくなった。
- 夜間・観測月なしの結果は図 3.40 である。データ全体と近接空間の学習・評価誤差は中心時刻によらず、先行研究のものより小さくなった。
- 夜間・中心時刻なしの結果は図 3.42 である。データ全体と近接空間の評価誤差は中心時刻によらず、先行研究のものより大きくなる傾向にあった。
- 夜間・時間長なしの結果は図 3.44 である。データ全体と近接空間の評価誤差は中心時刻によらず、先行研究のものより大きくなる傾向にあった。




図 3.35: 夜間・5 入力 of 予測誤差の比較




図 3.36: 夜間・5 入力 of 予測誤差の比較




図 3.37: 夜間・地域類型なし of 予測誤差の比較




図 3.38: 夜間・地域類型なし of 予測誤差の比較




図 3.39: 夜間・観測月なし of 予測誤差の比較




図 3.40: 夜間・観測月なし of 予測誤差の比較




図 3.41: 夜間・中心時刻なし of 予測誤差の比較




図 3.42: 夜間・中心時刻なし of 予測誤差の比較





図 3.43: 夜間・時間長なしの予測誤差の比較 図 3.44: 夜間・時間長なしの予測誤差の比較

3.5.3 NN と SVM の比較

NN と SVM の昼間の予測結果を比較すると、データ全体と近接空間の時間長別の評価誤差は NN の方が予測誤差が小さくなった。よって昼間の長時間 L_{Aeq} を予測するには NN の方が良い。夜間の予測結果は地域類型なしの予測結果を除いて、NN と SVM で時間長別の予測・中心時刻別の予測に大きな差はなかった。

NN および SVM の学習時間は表 3.4 のようになった。NN の学習は 7 分程度で終了するが、SVM は学習時間が最も短いものでも 1 時間 30 分以上もかかっている。また、学習・評価誤差についても NN と SVM による差はほとんどない。よって、短時間 L_{Aeq} から長時間 L_{Aeq} の予測については、NN で十分である。

表 3.4: NN および SVM の学習時間

データ区分	5 入力	地域分類なし	観測月なし	中心時刻なし	時間長なし
NN, 昼間	7 分 21 秒	6 分 33 秒	6 分 31 秒	6 分 40 秒	6 分 31 秒
NN, 夜間	7 分 22 秒	7 分 31 秒	7 分 34 秒	6 分 57 秒	6 分 33 秒
SVM, 昼間	176 分 54 秒	118 分 33 秒	143 分 50 秒	127 分 26 秒	126 分 36 秒
SVM, 夜間	144 分 46 秒	108 分 47 秒	105 分 24 秒	102 分 16 秒	103 分 27 秒

3.6 まとめ

5 入力から予測したものと観測月がない入力要素の組み合わせから予測したものを比較すると学習・評価誤差がほとんど変化しなかったため、観測月は長時間 L_{Aeq} の予測に役立っていない可能性がある。また、長時間 L_{Aeq} の予測に役立っていると考えられる入力要素を記述すると、昼間の場合は時間長であり、夜間の場合は中心時刻と時間長である。

第4章 長時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測

4.1 はじめに

本章では、NN または SVM を用いて環境騒音に対する住民反応を予測することを試みる。ここでいう住民反応とはアンケート調査の選択肢への回答とし、具体的には 2.3 で説明したデータベースに含まれる「あなたの自宅周辺の生活環境は騒音が大きい方だと思いますか?」への回答である。環境アセスメントにおいて、きめ細やかな対応をするために住民が環境騒音に対してどのように感じているかを知る必要がある。しかし、そのような調査には大きな労力を要するので、住民反応の予測が重要となる。

4.2 先行研究と本研究の目的

目的が同じ NN を利用した先行研究を紹介する。

先行研究 [3] で使用された NN の構成を図 4.1 に示す。この NN は用途地域を基に商業区、工業区、住居区の 3 つに分けて学習・評価している。学習条件は 4.1 のようになっている。この学習条件から商業区、工業区および住居区のそれぞれについて、正答率が最大になる正則化パラメータと中間素子数は表 4.2 のように決定した。




図 4.1: 先行研究の NN の構造

表 4.1: 学習条件

学習アルゴリズム	Kick-Out 法
学習回数	20000 回
初期値試行	200 回
正則化パラメータ η の範囲	[0.00001, 1.0]
中間素子数	[1, 5]

表 4.2: 正則化パラメータと中間素子数の決定結果

地域区	中間素子数	正則化パラメータ η
商業区	2	0.003
工業区	1	0.0001
住居区	5	0.00006

この方法で予測したときの商業区、工業区および住居区の正則化を導入した場合の正答率は表 4.3 のようになった。工業区の正答率が他の 2 地域に比べて悪くなっている。

表 4.3: 地域毎の正則化を導入した場合の正答率の算出結果

地域区	正則化を導入した場合
商業区	75.68%
工業区	66.13%
住居区	79.02%

商業区、工業区および住居区の住民反応の割合は図 4.2 のようになった。住居区で 4%ほどの誤差があるのを除いて、予測用データとほぼ等しい反応割合となった。

しかし、先行研究では次のような問題点が挙げられる。

- 予測する NN を商業区、工業区および住居区によって分けている。
- 住民反応をそのまま予測せず、陽性反応と印正反応の 2 種類に集約して予測している。

本研究では NN と SVM の 1 つの統一したモデルを作成し、3 種類の住民反応をそのまま予測することを試みた。さらに、NN と SVM の入力要素の見直しを行った。




図 4.2: 各地域の住民反応の割合

4.3 住民反応の予測と評価方法

反応の予測については各個人の回答（個別反応）と反応の個人差を平均化する意味での集団の回答割合（反応割合）の2つを予測することを考えた。

環境騒音に対する住民反応の予測評価に使用する指標は2つある。1つは住民反応の正答率である。この指標はNNおよびSVMが住民反応を正しく予測できた割合である。もう1つは住民反応の反応割合である。この指標は3種類の各住民反応の割合を予測したものである。個別予測は1地点の住民反応を予測することを表わしている。集団予測は集団全体の住民反応を予測することを表わしている。

4.4 予測に試用したNN及びSVMの構成

この研究に用いたNNの構成を図4.3に示す。NNの中間層の数は入力層と同じ数に設定している。出力層は住民反応が「大きい」「普通」「小さい」となる確率をそれぞれ表わしている。各層の間の能動関数はシグモイド関数を使用している。シグモイド関数は図4.4のようなグラフとなり、0~1の値を取るので、NNである量の確率を予測するのに好都合である。NNの学習回数はしっかりと学習が収束するように200,000回にした。SVMの構成を図4.5に示す。SVMの中間層はアルゴリズムにより自動で決定される。SVMのカーネル関数は $\sigma = \omega = 1$ のPukカーネルであり、試行錯誤をして C の値を100を選択した。

4.4.1 個別反応の予測（個別予測）

NNの場合、3つの出力要素の中で最も大きい数値を取るものが予測した住民反応になる。SVMの場合、アルゴリズムにより3種類の住民反応の境界線を決定し、「大きい」「普通」「小さい」のいずれか1つが出力される。

4.4.2 反応割合の予測（集団予測）

この予測方法は前節で説明した4.3の出力を規格化された各住民反応の確率にする方法である。この予測方法は住民反応を直接的に予測できない。しかし、住民反応の反応割合を高精度で予測することができる。なお、SVMはそのアルゴリズムの性質から1出力のネットワークしか作れないので、この予測方法はSVMでは行うことはできない。そこで、SVMの場合は「大きい」「普通」「小さい」と予測したそれぞれの出力の合計を全データ数で割って、反応割合を求めた。




図 4.3: 4 章の NN の構成




図 4.4: シグモイド関数




図 4.5: 4 章の SVM の構成

4.5 学習・評価用データセット

上述した名古屋市の環境騒音データベース [5][6] では住民反応のデータが 2 地点分欠落していたため、環境騒音に対する住民反応の予測に使用したデータ数は学習データは 1024 地点、評価データは 1025 地点の計 2049 地点となった。地域類型別のデータ数は表 4.5 の

ようになる。A 地域（道）、B 地域（他）と C 地域（他）のデータ数は少ないが、分析を行う。未分類はあまりにデータ数が少なく、特徴をつかむことができなかったため、分析を行わなかった。

表 4.4: 地域類型別の学習・評価データ数

地域類型	学習データ	評価データ
近接空間	209	208
A 地域（道）	40	39
A 地域（他）	208	207
B 地域（道）	34	39
B 地域（他）	237	238
C 地域（道）	259	258
C 地域（他）	26	26
未分類	11	10

SVM と NN の入力要素には、24 時間分の 144 個の $L_{Aeq,1/6h}$ をそのまま入力するのではなく、騒音に係る環境基準（新・旧）を参考に表 4.5 のような複数の時間帯の騒音レベルに集約した上で入力することにした。なお、夜間については新・旧基準とも同じである。

表 4.5: 騒音に係る環境基準の時間帯

新基準	昼間	6:00 ~ 22:00	$L_{Aeq,D}$
新基準	夜間	22:00 ~ 6:00	$L_{Aeq,N}$
旧基準	朝	6:00 ~ 8:00	$L_{Aeq,M}$
旧基準	昼間	8:00 ~ 19:00	$L_{Aeq,D'}$
旧基準	夕方	19:00 ~ 22:00	$L_{Aeq,E}$

その他の入力要素としては、 $L_{Aeq,1/6h}$ の最大値、最小値と地域類型を組み合わせで使用した。

予測する住民反応は表 4.5 の質問項目への回答である。

表 4.6: 予測対象（住民反応）

[質問項目]		
あなたの自宅周辺の生活環境は騒音が大きい方だと思いますか？		
1. 大きい	2. 普通	3. 小さい

4.6 個別反応の学習・予測結果

本節では、どのような入力要素の組み合わせが正答率が高いのかを考察する。

4.6.1 入力要素の検討(1)

地域類型の有無と1日の L_{Aeq} を2分割または4分割することによる予測への影響を調べるため、以下の4つの入力要素の組み合わせで予測した。

- 分類 1; L_{AeqD}, L_{AeqN}
- 分類 2; 地域類型, L_{AeqD}, L_{AeqN}
- 分類 3; $L_{AeqM}, L_{AeqD'}, L_{AeqE}, L_{AeqN}$
- 分類 4; 地域類型, $L_{AeqM}, L_{AeqD'}, L_{AeqE}, L_{AeqN}$

NN および SVM で予測した評価データ全体の住民反応の正答率表は4.7 のようになった。1 日の L_{Aeq} を2 分割したものが最も高い正答率を出している。地域類型が入っているものの方が正答率が少し悪くなる。また、NN と SVM による全体の正答率の差は小さい。

表 4.7: NN および SVM の住民反応の正答率(1)

データ区分	NN, 正答率	SVM, 正答率
分類 1	51.7%	52.2%
分類 2	50.93%	50.5%
分類 3	51.3%	50.6%
分類 4	51.3%	49.8%

NN および SVM で予測した評価データの住民反応の正答率は表 4.8 のようになった。この結果から入力要素は1 日の L_{Aeq} を2 分割したものよりも4 分割したものを方が予測精度が良いことがわかる。また、同じ入力要素の組み合わせでは NN よりも SVM の方が「大きい」「小さい」の正答率が高い。

表 4.8: NN および SVM の住民反応の個別正答率 (1)

データ区分	「大きい」の正答率	「普通」の正答率	「小さい」の正答率
NN, 分類 1	38.0%	87.4%	0.0%
NN, 分類 2	32.3%	89.3%	0.0%
NN, 分類 3	37.4%	83.4%	6.8%
NN, 分類 4	32.7%	87.4%	4.8%
SVM, 分類 1	37.4%	87.8%	2.0%
SVM, 分類 2	34.0%	82.2%	10.0%
SVM, 分類 3	36.0%	82.8%	6.8%
SVM, 分類 4	37.7%	74.2%	17.5%

4.6.2 入力要素の検討 (2)

この節では、分類 4 に $L_{Aeq,1/6h}$ の最大値・最小値を入力要素に加えたことによる予測の影響を比較するため、以下の 3 つの入力要素の組み合わせで予測した。 L_{Aeqmax} 、 L_{Aeqmin} はそれぞれ $L_{Aeq,1/6h}$ の最大値、最小値を表わしている。

- 分類 5; 地域類型, L_{AeqM} , $L_{AeqD'}$, L_{AeqE} , L_{AeqN} , L_{Aeqmax}
- 分類 6; 地域類型, L_{AeqM} , $L_{AeqD'}$, L_{AeqE} , L_{AeqN} , L_{Aeqmin}
- 分類 7; 地域類型, L_{AeqM} , $L_{AeqD'}$, L_{AeqE} , L_{AeqN} , L_{Aeqmax} , L_{Aeqmin}

これらの入力要素とした NN および SVM で予測した評価データ全体の住民反応の正答率は表 4.9 のようになった。 $L_{Aeq,1/6h}$ の最大値・最小値を入力要素に加えたことによる正答率の向上は見られなかった。

表 4.9: NN および SVM の住民反応の正答率 (2)

データ区分	NN, 正答率	SVM, 正答率
分類 5	51.5%	51.6%
分類 6	49.8%	49.8%
分類 7	50.7%	49.6%

これらの入力要素とした NN および SVM で予測した評価データの住民反応の正答率は表 4.10 のようになった。入力要素に L_{Aeqmax} 、 L_{Aeqmin} が入っていないものに比べて、「大きい」「小さい」の正答率は上がるが、「普通」の正答率は下がる。

表 4.10: NN および SVM の住民反応の個別正答率 (2)

データ区分	「大きい」の正答率	「普通」の正答率	「小さい」の正答率
NN, 分類 5	32.0%	79.0%	22.3%
NN, 分類 6	35.7%	75.9%	16.7%
NN, 分類 7	39.7%	76.9%	13.9%
SVM, 分類 5	47.5%	68.6%	24.3%
SVM, 分類 6	42.8%	65.6%	27.9%
SVM, 分類 7	46.1%	61.0%	32.3%

4.7 反応割合の学習・予測結果

本節では、どのような入力要素の組み合わせが反応割合の予測精度が良いのかを考察する。評価データ全体の反応割合は図 4.6 と図 4.7 のようになった。SVM の予測結果よりも NN の予測結果の方がはるかに予測精度が良いので、これ以降、反応割合の結果は NN の予測結果のみを示す。




図 4.6: NN の評価データ全体の反応割合




図 4.7: SVM の評価データ全体の反応割合

全体と地域類型別の反応割合の平均誤差を図 4.8 ~ 図 4.11 に示す。グラフの特徴を分かりやすくするために図を 4 つに分けて示した。反応割合の平均誤差とは 3 種類の反応割合の実測値と予測値の誤差を平均したものである。評価データ全体の反応割合の平均誤差は図 4.8 のようになり、入力要素の組み合わせによらず、ほぼ同じ結果となった。近接空間の反応割合の平均誤差は図 4.9 のようになり、入力要素に $L_{Aeq,1/6h}$ の最大値が入っている分類 5 と分類 7 が一番良い結果となった。A 地域と B 地域の反応割合の平均誤差は図 4.10 のようになり、A 地域の道路沿いを除いて、入力要素に $L_{Aeq,1/6h}$ の最小値が入っている分類 6 が一番良い結果となった。A 地域の道路沿いは入力要素に地域類型が入っており、1 日の L_{Aeq} を 4 分割にしたものである分類 4 が一番良い結果となった。C 地域の反応割合の平均誤差は図 4.11 のようになり、入力要素に $L_{Aeq,1/6h}$ の最大値・最小値を入れても、平均誤差が増加する傾向にある。最も良い結果となったのは、入力要素に地域類型が入っており、1 日の L_{Aeq} を 4 分割にしたものである。入力要素の組み合わせの比較をすると、地域類型が入っているものの方が良い結果となった。ただし、B 地域の道路沿いの

み地域類型が入っている分類の方が平均誤差が大きくなった。また、分類2と分類4の地域類型による予測精度をみると、良いのは近接空間とA地域の道路沿いであり、悪いのはA地域の道路から離れている地域とB地域である。




図 4.8: 全体の反応割合の誤差




図 4.9: 近接空間の反応割合の誤差




図 4.10: A 地域と B 地域の反応割合の誤差




図 4.11: C 地域の反応割合の誤差

それぞれの地域類型別の反応割合は図 4.12 ~ 図 4.18 である。




図 4.12: NN の近接空間の反応割合




図 4.13: NN の A 地域 (道) の反応割合




図 4.14: NN の A 地域 (他) の反応割合




図 4.15: NN の B 地域 (道) の反応割合




図 4.16: NN の B 地域 (他) の反応割合




図 4.17: NN の C 地域 (道) の反応割合




図 4.18: NN の C 地域 (他) の反応割合

4.8 先行研究との結果の比較

本節では先行研究と本研究の結果を比較する。反応割合を比較するために、本研究で利用した住民反応を「大きい」「普通・小さい」の2種類に要約した。本研究の方法で予測

した本研究の商業区、工業区および商業区の2種類に要約された住民反応の割合は図4.19のようになった。工業区では反応割合の誤差は2%程度あるが、他の区域では反応割合の誤差は非常に小さいことがわかる。この予測をしたNNの構成は図4.20である。このNNの中にある新しい入力要素である「地域区」は測定地点の区域を表わしており、商業区、工業区、住居区の3つに分けている。他の入力要素は先行研究と同じ入力要素である。また、予測する住民反応は2種類であるが、NNの出力要素の数を3つにしているのは本研究の予測方法と同じにするためである。住民反応が評価データ全体の住民反応が「大きい」となる反応割合の誤差は図4.21のようになった。どの入力要素の組み合わせでも誤差が2%以内に収まっている。これらのことから本研究で示した方法は反応割合を予測するという点では先行研究の方法より予測精度が良いと判断できる。




図 4.19: 2 種類に要約した住民反応の割合




図 4.20: 予測に用いた NN の構成




図 4.21: 「大きい」の反応割合の誤差

4.9 まとめ

まず、正答率の結果について述べる。評価データ全体の正答率はどの入力要素の組み合わせで NN または SVM を用いるかによらず 49.6% ~ 52.2% となり、数%の差しかなかった。個別正答率については 1 日の L_{Aeq} を 4 分割にしたものと地域類型、 $L_{Aeq,1/6h}$ の最大値、最小値を入力要素にしたものを SVM で予測するのが最も良い。なぜなら、この予測方法で得られた「大きい」と「小さい」の個別正答率の合計が最も高かったからである。また、NN より SVM の方が高くなった。また、「普通」の個別正答率だけが他の 2 つの個別正答率に比べて非常に高いので、NN と SVM の両方の個別出力は「普通」に偏りすぎていることが分かった。「大きい」「小さい」の正答率が高いものほど「普通」の正答率が低くなる傾向にあった。このことがデータ全体の正答率が入力要素の組み合わせによって大きく変わらない理由であると考えられる。

次に、反応割合の結果について述べる。データ全体の反応割合は入力要素に地域類型が入っており、逆に $L_{Aeq,1/6h}$ の最大値、最小値が入っていないものが最も良い結果となった。1 日の L_{Aeq} を 2 分割を 4 分割にすると若干の誤差の低下は認められる。しかし、そ

れほど大きな効果は期待できない。地域類型別の結果をみると、入力要素に地域類型を入れる方が良いことがわかる。学習・評価を1つのNNで行っているので、当然である。近接空間では $L_{Aeq,1/6h}$ の最大値を入力要素に加えると反応割合の平均誤差が非常に小さくなる。これは近接空間は道路騒音の影響を強く受けており、主に昼間の L_{Aeq} の最大値が反応に影響するからだと思像できる。A地域とB地域ではA地域の道路沿いを除いて、 $L_{Aeq,1/6h}$ の最小値を入力要素に加える方が反応割合の平均誤差は小さくなる。これは住居系の地域では相対的に道路騒音の影響が小さくなり、主に夜間の静かさ（ $L_{Aeq,1/6h}$ の最小値）との関連性があるためだと思像できる。A地域の道路沿いでは $L_{Aeq,1/6h}$ の最小値を入力要素に加えない方が反応割合の平均誤差は小さくなる。C地域では $L_{Aeq,1/6h}$ の最大値、最小値を加えない方が反応割合の平均誤差は小さくなる。

どのような予測方法が良いかをまとめると、正答率については1日の L_{Aeq} を4分割したものと地域類型、 $L_{Aeq,1/6h}$ の最大値、最小値を入力要素にし、SVMで予測するのが1番良い。反応割合についてはSVMよりNNで予測した方が良い。しかし、予測地点の地域類型によって、NNによる予測が最も良くなる入力要素の組み合わせが異なり、詳しくは以下になる。

- 近接空間では1日の L_{Aeq} を4分割にし、地域類型と $L_{Aeq,1/6h}$ の最大値、最小値を入力要素にすると良い
- A地域の道路沿いを除くA地域とB地域では1日の L_{Aeq} を4分割にし、地域類型と $L_{Aeq,1/6h}$ の最小値を入力要素にすると良い
- A地域の道路沿いとC地域では1日の L_{Aeq} を4分割にし、地域類型を入力要素にすると良い

第5章 短時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測

5.1 はじめに

前節では、住民反応の予測に使用する騒音評価値について1日24時間の計測を前提としていた。しかし、実務の上において、短時間の計測から得られた L_{Aeq} を用いて住民反応の予測できれば好都合である。そこで、本章では短時間 L_{Aeq} を用いて住民反応の予測を行うことを考える。短時間 L_{Aeq} は昼間のものを使用する場合と夜間のものを使用する場合の2つに分ける。

5.2 NN およびSVM の構成

この予測に使用したNNの構成は図5.1のようになる。NNの学習回数は200,000回にすると、非常に時間がかかるので、30,000回にした。ただし、学習がしっかりと収束していることを学習終了時とその1,000回前の学習誤差を比較して確かめた。SVMの構成は図5.2である。SVMのカーネル関数は $\sigma = \omega = 1$ のPukカーネルである。なお、 C の値を100にするとSVMは24時間かけても学習が終了しなかったので、 $C = 1$ とした。




図 5.1: 5 章の NN の構成




図 5.2: 5 章の SVM の構成

5.3 学習・評価用データセット

使用したデータ数は4章と同じく、学習データが1024地点、評価データ1025地点の計2049地点である。入力要素は3章で使った5つを使用した。出力要素は4章と同じものを使用する。ただし、入力要素の短時間 L_{Aeq} を昼間のものと夜間のものに区別するため、入力要素の組み合わせは

- 分類 D; 地域類型, 観測月, 中心時刻, 時間長, 昼間の短時間 L_{Aeq}
- 分類 N; 地域類型, 観測月, 中心時刻, 時間長, 夜間の短時間 L_{Aeq}

のように2つに分ける。

5.4 正答率の学習・予測結果

NN および SVM で予測した評価データ全体の正答率は表 5.1 のようになった。NN または SVM、昼間または夜間の短時間 L_{Aeq} を用いるかによらずあまり差が出なかった。

表 5.1: 短時間予測の住民反応の正答率

	NN, 昼間	NN, 夜間	SVM, 昼間	SVM, 夜間
正答率	50.5%	51.6%	51.3%	51.5%

NN および SVM で予測した住民反応の個別正答率は表 5.2 のようになった。NN の夜間は「小さい」の正答率が他のものに比べて良いことがわかる。「大きい」「普通」の正答率に関してはどの場合もあまり変わらない。

表 5.2: 短時間予測の住民反応の個別正答率

データ区分	「大きい」の正答率	「普通」の正答率	「小さい」の正答率
NN, 昼間	31.4%	88.9%	0.1%
NN, 夜間	33.4%	82.9%	13.7%
SVM, 昼間	33.6%	89.2%	0.1%
SVM, 夜間	35.2%	88.8%	0.0%

5.5 反応割合の学習・予測結果

前章と同じ理由で SVM は NN に比べて反応割合の予測精度が明らかに低いので、NN からの予測のみを行った。分類別の反応割合の平均誤差は図 5.3 と図 5.4 のようになった。長時間 L_{Aeq} からの予測との比較のために、前章の分類 2（地域類型, L_{AeqD} , L_{AeqN} ）と分類 4（地域類型, L_{AeqM} , L_{AeqD} , L_{AeqE} , L_{AeqN} ）の結果を一緒に載せた。分類 D からの予測は全ての結果で前章の分類 2 の結果とほぼ等しくなった。分類 N からの予測について述べる。A 地域の道路沿いと B 地域の道路から離れている地域の予測結果は分類 2 の結果よりも悪くなった。特に A 地域の道路沿いの予測結果は非常に悪くなった。一方、A 地域の道路から離れている地域と B 地域の道路沿いの予測結果は分類 2 のものよりも 2% 程度の平均誤差が小さくなった。よって、長時間 L_{Aeq} からの予測で予測精度が悪かった地域類型を除いて、短時間 L_{Aeq} からの予測でも反応割合の傾向は合っている。




図 5.3: 反応割合の平均誤差 (1)




図 5.4: 反応割合の平均誤差 (2)

評価データ全体の住民反応の割合と地域類型別の結果は図 5.5 ~ 図 5.12 のようになった。




図 5.5: NN の評価データ全体の反応割合




図 5.6: NN の近接空間の反応割合




図 5.7: NN の A 地域 (道) の反応割合




図 5.8: NN の A 地域 (他) の反応割合




図 5.9: NN の B 地域 (道) の反応割合




図 5.10: NN の B 地域 (他) の反応割合




図 5.11: NN の C 地域 (道) の反応割合




図 5.12: NN の C 地域 (他) の反応割合

時間長別の住民反応を予測した場合、反応割合の平均誤差を図 5.13～図 5.18 に示す。分類 D または分類 N から予測した評価データ全体と近接空間の反応割合の平均誤差はそれぞれ図 5.13、図 5.14 である。使用する短時間 L_{Aeq} が昼間であるか夜間であるかに関係なく、時間長によって平均誤差はほとんど変化しないことが分かる。分類 D または分類 N から予測した A 地域と B 地域の反応割合の平均誤差はそれぞれ図 5.15、図 5.16 である。使用する短時間 L_{Aeq} が昼間であるか夜間であるかによって様相が大きく異なる。また、分類 D の B 地域の道路沿い、分類 N の A 地域の道路沿いは時間長が長くなると、平均誤差が微増するが、それ以外のものは時間長によって平均誤差はほとんど変わらなかった。分類 D または分類 N から予測した C 地域の反応割合の平均誤差はそれぞれ図 5.17、図 5.18 である。使用する短時間 L_{Aeq} が昼間であるか夜間であるかに関係なく、時間長によって平均誤差はほとんど変化しない。よって、地域分類別の反応割合の予測においても騒音計測時間は 1 時間で十分である。

中心時刻別の住民反応を予測した場合、反応割合の平均誤差を図 5.19～図 5.24 に示す。時間長は全て 1 時間のデータを選択している。分類 D または分類 N から予測した評価データ全体と近接空間の反応割合の平均誤差はそれぞれ図 5.19、図 5.20 である。分類 D から予測した場合、中心時刻の変化による平均誤差の変化は 1% 程度であるが、分類 N から予測した場合、分類 D から予測したものよりも平均誤差の変化が大きい。分類 D または分類 N から予測した A 地域と B 地域の反応割合の平均誤差はそれぞれ図 5.21、図 5.22 である。この地域は使用する短時間 L_{Aeq} が昼間であるか夜間であるかによって様相が大きく異なり、分類 N から予測したものは分類 D から予測したものよりも平均誤差の変化が大きい。分類 D または分類 N から予測した C 地域の反応割合の平均誤差はそれぞれ図 5.23、図 5.24 である。この地域は使用する短時間 L_{Aeq} が昼間であるか夜間であるかに関係なく、平均誤差の変化が少ない。




図 5.13: 分類 D の反応割合の平均誤差 (1)




図 5.14: 分類 N の反応割合の平均誤差 (1)




図 5.15: 分類 D の反応割合の平均誤差 (2)




図 5.16: 分類 N の反応割合の平均誤差 (2)




図 5.17: 分類 D の反応割合の平均誤差 (3)




図 5.18: 分類 N の反応割合の平均誤差 (3)





図 5.19: 分類 D の反応割合の平均誤差 (1) 図 5.20: 分類 N の反応割合の平均誤差 (1)





図 5.21: 分類 D の反応割合の平均誤差 (2) 図 5.22: 分類 N の反応割合の平均誤差 (2)





図 5.23: 分類 D の反応割合の平均誤差 (3) 図 5.24: 分類 N の反応割合の平均誤差 (3)

5.6 まとめ

正答率の結果について述べる。データ全体の正答率は NN または SVM、昼間または夜間の短時間 L_{Aeq} を用いるかによる差はほとんどなかった。個別正答率に関しては NN で夜間の L_{Aeq} を用いたものが「小さい」の正答率が最も高い。また、前章と同じく「普通」の個別正答率が他の 2 つの個別正答率に比べて非常に高いので、個別出力が「普通」に偏りすぎている。反応割合に関しては時間長が長くなるほど予測精度が良くなる傾向はなかった。短時間 L_{Aeq} からの予測では、騒音の計測時間は 1 時間で良いと考えられる。また、C 地域以外の反応割合の平均誤差は中心時刻によって少し変化し、昼間の短時

間 L_{Aeq} よりも夜間の短時間 L_{Aeq} を用いた方が変化が大きい。C 地域の反応割合の平均誤差は中心時刻による変化がほとんどなく、使用する短時間 L_{Aeq} が昼間であるか夜間であるかによらない。地域類型が A 地域と B 地域では昼間または夜間の短時間 L_{Aeq} を用いるかによって様相が大きく異なる。特に A 地域（道）の平均誤差は昼間または夜間の短時間 L_{Aeq} を用いるかによる違いは大きく、昼間の道路騒音が住民反応に大きな影響を与えていると想像できる。

長時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測と短時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測を比較する。短時間 L_{Aeq} からの予測では正答率に関しては長時間 L_{Aeq} からの予測よりも低かった。反応割合の結果を比較すると、

- 近接空間では使用する短時間 L_{Aeq} が昼間・夜間によらず平均誤差が 2% 程度であり、長時間からの予測と同程度だが、最大値レベルを追加した場合の 1% 未満の平均誤差には劣っている。
- A 地域の道路沿いで昼間の短時間 L_{Aeq} を使用すれば長時間 L_{Aeq} からの予測と同程度であるが、A 地域と B 地域の他の地域類型では 1% 以上の平均誤差の増加した。
- C 地域では長時間 L_{Aeq} からの予測とほぼ同程度の平均誤差となった。

反応割合の予測についてまとめると、

- 近接空間では 24 時間の測定を行い、1 日の $L_{Aeq,1/6h}$ の最大値を入力要素に加えると 1% 未満の誤差の予測が可能である。
- A 地域と B 地域では 24 時間の測定を行い、1 日の $L_{Aeq,1/6h}$ の最小値を入力要素に加えると 3~5% 程度の誤差になる。ただし、A 地域の道路沿いでは 1 日の $L_{Aeq,1/6h}$ の最小値を入力要素に加えない方が良く、2% 程度の誤差になる。また、A 地域の道路沿いを除き、短時間からの予測では誤差が 1% 以上増加する。
- C 地域では 1 時間の騒音評価量から予測しても長時間からの予測と同程度の予測が可能であり、その誤差は 2~4% 程度である。

これらのことから要求される精度や測定地域により、測定時間の短縮を行っても良い可能性が示せた。しかし、本研究は名古屋市だけのデータから得られた結論であり、東京や大阪などの他の都市についても同様の結果が得られるかどうかはわからない。

第6章 総括

短時間 L_{Aeq} から長時間 L_{Aeq} の予測については、NN と SVM の学習・評価誤差に大きな差は出なかった。また、入力要素の組み合わせによるデータ全体の学習・評価誤差にも大きな差は見られなかった。しかし、時間長別・中心時刻別に学習・評価誤差を比較すると、昼間は「時間長」、夜間は「中心時刻」と「時間長」を入力要素として残しておいた方が良かったことがわかった。逆に、「観測月」がない入力要素の組み合わせは昼間・夜間ともに先行研究の予測とほとんど変わらず、「観測月」が予測にあまり貢献していないことがわかった。

長時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測については正答率なら SVM で予測する方が NN で予測するより高い。反応割合なら NN で予測する方が SVM で予測するより予測精度が高い。評価データ全体の正答率はどの入力要素の組み合わせにおいても NN または SVM を用いるかによらず 49.6% ~ 52.2% となり、数%の差しかなかったが、個別正答率では大きく異なる。個別正答率が最も高くなる入力要素の組み合わせは1日の L_{Aeq} を4分割にし、 $L_{Aeq,1/6h}$ の最大値、最小値を加えた入力要素のものである。反応割合が良い入力要素の組み合わせは地域類型によって異なり、詳しくは以下になる。

- 近接空間では1日の L_{Aeq} を4分割にし、 $L_{Aeq,1/6h}$ の最大値、最小値を入力要素にしたものである。
- A 地域と B 地域では1日の L_{Aeq} を4分割にし、 $L_{Aeq,1/6h}$ の最小値を入力要素にしたものである。ただし、A 地域の道路沿いでは $L_{Aeq,1/6h}$ の最小値を入力要素に加えていないものの方が1% 程度良い。
- C 地域では4分割された1日の L_{Aeq} を入力要素にしたものである。

短時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測については正答率の場合、データ全体の正答率は NN または SVM のいずれにおいても昼間または夜間の短時間 L_{Aeq} を用いるかによる差はほとんどなかった。個別正答率では NN で夜間の短時間 L_{Aeq} を用いたものが「小さい」の正答率が最も高い。また、長時間 L_{Aeq} からの予測した場合と同じく「普通」の個別正答率が他の2つの個別正答率に比べて非常に高いので、個別出力が「普通」に偏りすぎている。反応割合の場合、時間長を長くしても予測精度が良くなる傾向がないので、短時間 L_{Aeq} からの予測では騒音計測時間は1時間で良いと考えられる。また、

C 地域を除いて反応割合の平均誤差は中心時刻により少し変化し、昼間の短時間 L_{Aeq} よりも夜間の短時間 L_{Aeq} を用いた方が変化が大きい。地域類型が A 地域と B 地域では昼間または夜間の短時間 L_{Aeq} を用いるかによって様相が大きく異なる。特に A 地域の道路沿いの平均誤差は昼間または夜間の短時間 L_{Aeq} を用いるかによる違いは大きく、昼間の道路騒音が住民反応に大きな影響を与えていると想像できる。

長時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測と短時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測を比較すると、短時間 L_{Aeq} からの予測では正答率に関しては長時間 L_{Aeq} からの予測よりも低かった。反応割合の結果を比較すると、

- 近接空間では使用する短時間 L_{Aeq} が昼間・夜間によらず平均誤差が 2% 程度であり、長時間からの予測と同程度だが、最大値レベルを追加した場合の 1% 未満の平均誤差には劣っている。
- A 地域と B 地域では A 地域の道路沿いで昼間の短時間 L_{Aeq} を使用すれば長時間 L_{Aeq} からの予測と同程度であるが、他の地域類型では 1% 以上の平均誤差の増加した。
- C 地域では長時間 L_{Aeq} からの予測とほぼ同程度の平均誤差となった。

住民反応の予測についてまとめると、

- 近接空間では 24 時間の測定を行い、1 日の $L_{Aeq,1/6h}$ の最大値を入力要素に加えると 1% 未満の誤差の予測が可能である。
- A 地域と B 地域では 24 時間の測定を行い、1 日の $L_{Aeq,1/6h}$ の最小値を入力要素に加えると 3~5% 程度の誤差になる。ただし、A 地域の道路沿いでは 1 日の $L_{Aeq,1/6h}$ の最小値を入力要素に加えない方が良く、2% 程度の誤差になる。また、A 地域の道路沿いを除き、短時間からの予測では誤差が 1% 以上増加する。
- C 地域では 1 時間の騒音評価量から予測しても長時間からの予測と同程度の予測が可能であり、その誤差は 2~4% 程度である。

これらのことから要求される精度や測定地域により、測定時間の短縮を行っても良い可能性が示せた。しかし、本研究は名古屋市だけのデータから得られた結論であり、東京や大阪などの他の都市についても同様の結果が得られるかどうかはわからない。

課題としては

- 短時間 L_{Aeq} から長時間 L_{Aeq} の予測において、入力要素の選択を考察したが、最適なものになったかを確認すること

- 長時間・短時間 L_{Aeq} を用いた環境騒音に対する住民反応の予測において、個別予測の出力が「普通」に偏りすぎており、それを解消する方法を見つけること
- 本研究は名古屋市だけのデータを用いているので、他の地域でも同様の方法で予測できるかどうかを確認すること

等が挙げられる。

謝辞

本研究の遂行に当たり、多大なるご指導と助言を賜った、野呂雄一准教授、竹尾隆教授、に心より感謝の意を表します。また、本研究のためにご協力下さった山本好弘技術職員、並びに院生学部生諸氏に深く御礼申し上げます。

参考文献

- [1] 日本騒音制御工学会, 騒音法令研究会, “騒音規制の手引き” (技報堂出版, 2002)
- [2] 益村 正周, 野呂 雄一, 竹尾 隆, 久野 和宏 “ニューラルネットワークを用いた環境騒音の短時間実測値からの予測評価” 三重大学工学研究科物理工学専攻ナノセンシング研究室修士論文集 (2009)
- [3] 永野 真, 久野和宏, 野呂雄一, 萩原克幸 “正則化ニューラルネットによる環境騒音に対する住民反応の予測” 三重大学工学研究科物理工学専攻ナノセンシング研究室修士論文集 (2004)
- [4] 吉田 雅俊, 久野和弘, 野呂雄一, 萩原克幸 “住環境騒音の分析・予測手法に関する研究” 三重大学工学研究科物理工学専攻ナノセンシング研究室修士論文集 (2001)
- [5] 久野和宏, “騒音と日常生活 社会調査データの管理・解析・活用法” (技報堂出版, 2003)
- [6] 久野和宏, 野呂雄一, “騒音の計測と評価 dB と L_{Aeq} ” (技報堂出版, 2006)
- [7] “騒音に係る環境基準について”, 平成 17 年 5 月 26 日 環境省告示 45 号 (2005)
- [8] 深川 雄司, 野呂 雄一, 竹尾 隆, 塩見繁, 久野和宏 “都市域における騒音測定調査の効率化に関する研究” 三重大学工学研究科物理工学専攻ナノセンシング研究室修士論文集 (2006)
- [9] Ochiai, Toda, Usui, “Kick-Out Learning Algorithm to Reduce the Oscillation of Weights”. Neural Networks, Vol.7, No.5, pp.797-807, (1994)
- [10] <http://www.cs.waikato.ac.nz/ml/weka/>
- [11] A.J. Smola, B. Schoelkopf (1998). A tutorial on support vector regression.